



Universidade Federal  
do Rio de Janeiro



Universidade Federal do Rio de Janeiro  
Programa de Pós-Graduação em Informática

**LEONARDO ROSA ZANETTE**

# SISTEMA DE RECOMENDAÇÃO DE ITENS BASEADO NA REDE DE CONFIANÇA DO USUÁRIO

Programa de Pós-Graduação em Informática

PPGI-UFRJ/NCE/IM

Orientadora:

Prof<sup>a</sup>. Claudia Lage Rebello da Motta, D.Sc.

Rio de Janeiro

2008

Leonardo Rosa Zanette

# SISTEMA DE RECOMENDAÇÃO DE ITENS BASEADO NA REDE DE CONFIANÇA DO USUÁRIO

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Informática (PPGI), Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Informática.

Orientadora: Claudia Lage Rebello da Motta.

Rio de Janeiro  
2008

Z28 Zanette, Leonardo Rosa.

Sistema de recomendação de itens baseado na rede de confiança do usuário / Leonardo Rosa Zanette. – Rio de Janeiro, 2008.

f.: il.

Dissertação (Mestrado em Informática) – Universidade Federal do Rio de Janeiro, Instituto de Matemática, Núcleo de Computação Eletrônica, 2008.

Orientadora: Cláudia Lage Rebello da Motta.

1. Redes de confiança – Teses. 2. Sistemas de Recomendação – Teses. 3. Comunidades Virtuais – Teses. I. Cláudia Lage Rebello da Motta (Orient.) III. Universidade Federal do Rio de Janeiro. Instituto de Matemática. Núcleo de Computação Eletrônica. IV. Título

CDD

Leonardo Rosa Zanette

# SISTEMA DE RECOMENDAÇÃO DE ITENS BASEADO NA REDE DE CONFIANÇA DO USUÁRIO

Dissertação submetida ao corpo docente do Programa de Pós-Graduação em Informática da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do grau de Mestre em Informática.

Aprovada em: 25 de agosto de 2008

---

Prof.<sup>a</sup>. Claudia Lage Rebello da Motta, D.Sc., NCE e PPGI/UFRJ (Orientadora)

---

Prof. Marcos da Fonseca Elia, Ph.D., NCE e PPGI/UFRJ

---

Prof. Carlo Emmanoel Tolla de Oliveira, Ph.D., NCE e PPGI/UFRJ

---

Prof.<sup>a</sup>. Flávia Maria Santoro, D.Sc., UNIRIO

---

Prof.<sup>a</sup>. Simone Diniz Junqueira Barbosa, D.Sc., PUC-RIO

## Agradecimentos

À Profª. D.Sc. Claudia Lage Rebello Motta, orientadora desta dissertação, por todo empenho, compreensão, estímulo, paciência e, acima de tudo, exigência, além de amizade e incentivo. Gostaria de ratificar a sua competência, participação com discussões, correções, sugestões e pelo tempo despendido, que fizeram com que concluíssemos este trabalho.

Ao Prof. D.Sc. Marcos da Fonseca Elia, pela sua colaboração com sugestões para avaliações estatísticas e suas aulas esclarecedoras quanto aos métodos científicos que deveriam nortear este trabalho.

Aos professores do Programa de Pós-Graduação em Informática: Fábio Ferrentini, Carlo Tolla, Marcos Borges, Flavia Santoro e Lígia Barros, pela oportunidade de crescimento, aprendizado, realização profissional e pessoal e pela confiança em mim depositada.

Aos colegas do Grupo GINAPE: Claudia Paranhos, Bruno Nascimento, Ricardo Marciano e Cynthia Fernanda, por sempre me incentivarem na busca do crescimento, sendo exemplos de competência, garra, determinação e disciplina.

Ao Prof. Dr. Marcos da Fonseca Elia, ao prof. Dr. Carlo Emmanoel Tolla, à Profª. Drª. Flávia Maria Santoro, à Profª. Drª. Simone Diniz Junqueira Barbosa por aceitarem participar da Banca de Defesa desta Dissertação, proporcionando discussões e sugestões que servirão para crescimento, aprendizado e incentivo à pesquisa.

A Profª. Eliza Helena de Souza Faria que me incentivou a fazer o Mestrado em Informática desde o tempo da faculdade, me apoiando em projetos e abrindo caminhos para meu crescimento dentro da área acadêmica.

Aos amigos e conhecidos que colaboraram no experimento deste trabalho contribuindo na coleta de dados e realização desta pesquisa.

Aos Funcionários do NCE pela amizade.

Aos meus familiares que sempre me deram amor e força, valorizando meus potenciais.

A todos os meus amigos e amigas que sempre estiveram presentes me aconselhando e incentivando com carinho e dedicação.

Ao NCE pela oportunidade de desenvolver essa dissertação de mestrado e pela bolsa de estudos que obtive no início do curso que me permitiu a realização deste trabalho.

A minha mãe e meu pai que sempre incentivaram e apoiaram a minha educação por entenderem que a educação é o melhor presente ao filho. Ao meu irmão Alexandre pelo apoio e incentivo.

Ao meu sogro, à minha sogra, cunhados e cunhadas que me apoiaram, incentivaram e contribuíram para que essa Dissertação de Mestrado fosse concluída.

A minha esposa Simone, que me deu “colo” nos momentos críticos deste mestrado e manteve-se incondicionalmente ao meu lado entendendo minhas faltas em decorrência do mestrado.

Ao meu filho Gabriel que me alegrava quando estava triste, que me dava ânimo quando estava desanimado, que me impulsionou para que esta Dissertação se concretizasse com êxito e me perdoou pelos vários momentos em que não pude estar presente em virtude do mestrado.

A todas as pessoas que, direta ou indiretamente, contribuíram para a execução dessa Dissertação de Mestrado.

## Resumo

ZANETTE, Leonardo Rosa. Sistema de Recomendação de Itens Baseado na Rede de Confiança do Usuário. Rio de Janeiro, 2008. Dissertação (Mestrado em Informática) - Instituto de Matemática/Núcleo de Computação Eletrônica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2008.

Esta dissertação apresenta uma abordagem de Sistemas de Recomendação de itens baseando-se na Rede de Confiança do usuário, além das típicas informações utilizadas nos Sistemas de Recomendação tradicionais. É proposto um modelo de Sistema de Recomendação onde é dada grande importância nas avaliações feitas pelas pessoas confiáveis do usuário. A avaliação do modelo foi feita em dois experimentos. No primeiro foi analisada uma grande comunidade de avaliação de filmes (*MovieLens*), muito utilizada em pesquisas de Sistemas de Recomendação, no sentido de validar e auxiliar na correta instanciação do modelo para sua aplicação em uma comunidade real. O segundo experimento foi utilizado para validação final da proposta, com a participação direta de um grupo de pessoas, em um protótipo desenvolvido na comunidade virtual *ActivUFRJ*. Os processos metodológicos conduzidos nesse segundo experimento envolveram a implementação, aplicação do modelo e a análise de um questionário aplicado aos participantes. As comparações dos experimentos foram realizadas em três níveis: cobertura das recomendações, teste de precisão e teste de hipóteses Z. A inclusão da Rede de Confiança constitui-se em uma alternativa para que o usuário alvo consiga identificar qual a importância de um determinado item recomendado frente à sua confiança nos recomendadores. Além disso, pode servir como instrumento de integração e fidelização de usuários dentro de uma comunidade, já que, com poucos usuários na sua Rede de Confiança pode-se gerar recomendações com qualidade. A idéia apresentada é que as avaliações e recomendações de um item por pessoas mais confiáveis têm grande relevância para o usuário alvo da recomendação.

## Abstract

ZANETTE, Leonardo Rosa. Sistema de Recomendação de Itens Baseado na Rede de Confiança do Usuário. Rio de Janeiro, 2008. Dissertação (Mestrado em Informática) - Instituto de Matemática/Núcleo de Computação Eletrônica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2008.

This thesis presents an approach to item based Recommender Systems using the user's web-of-trust, in addition to the typical information used in traditional Recommender Systems. It proposed a model of Recommender System which is given great importance in the assessments made by people trusted user. The evaluation of the model was made in two experiments. At first it was considered a large community-assessment movies (MovieLens), widely used in studies of Recommender Systems, in to validate and help correct instantiation of the model for its application in a real community. The second experiment was used for final validation the proposal, with direct participation of a group of people in a prototype developed in the ActivUFRJ virtual community. Cases methodological conducted this second experiment involved the deployment, implementation of model and analysis of a questionnaire administered to participants. Comparisons the experiments were conducted at three levels: recommendations coverage, precision test and hypotheses test Z. The inclusion of the Trust Network represents an alternative to the target user can identify which importance of a particular item recommended front of their confidence in Recommended. Moreover, it can serve as an instrument of integration and loyalty of users within a community, since, with few users in the Trust network you can generate recommendations with quality. The Idea presented is that the evaluations and recommendations of an item for most Trusted people have great relevance to the target user's recommendation.



## Lista de Figuras

---

Figura 1: Organização da dissertação em capítulos.....	23
Figura 2: Sistema de Recomendação de filmes, tela do Liveplasma.com. ....	33
Figura 3: Sistema de Recomendação de músicas, tela do last.fm.....	34
Figura 4: Sistema de Recomendação de serviços, tela do <i>GoogleMaps</i> . ....	35
Figura 5: Exemplo de uma Rede de Confiança. ....	51
Figura 6. Rede de Confiança. Os nós representam os usuários e as arestas os valores de confiança na direção da seta. A linha pontilhada representa um valor que pode ser predito pelo sistema. ...	51
Figura 7: Exemplo de Rede de Confiança subjetiva. ....	54
Figura 8: Exemplo de Rede de Confiança assimétrica.....	54
Figura 9: Rede de Confiança contextualizada, cada aresta indica um grau de confiança para cada contexto específico. ....	55
Figura 10: Transitividade direta em uma Rede de Confiança, a aresta tracejada indica um valor que pode ser inferido a partir da relação de <i>A</i> com <i>B</i> e <i>B</i> com <i>C</i> . ....	55
Figura 11: Exemplos de propagação de confiança direta. As arestas pontilhadas representam os valores de confiança que podem ser preditos. ....	57
Figura 12: Exemplo de confiança pela similaridade.....	58
Figura 13: Confiança agregada pelo caminho de valor máximo. ....	59
Figura 14: Confiança agregada pelo caminho de valor mínimo.....	59
Figura 15: Mapa conceitual do modelo, Filtragem Colaborativa somada à Rede de Confiança do usuário para gerar recomendações.....	64
Figura 16: Confianças diretas dos usuários. ....	69
Figura 17: Propagação de confiança, linhas pontilhadas indicam as confianças propagadas inferidas. ....	70
Figura 18: Diagrama entidade-relacionamento das informações necessárias para aplicação do modelo.....	74
Figura 19: Página de perfil do usuário no ActivUFRJ. ....	79
Figura 20: Página do Usuário no ActivUFRJ.....	80
Figura 21: Página da Comunidade no ActivUFRJ. ....	81
Figura 22: Página de um Artefato no ActivUFRJ. ....	82
Figura 23: Formulário de avaliação do artefato no ActivUFRJ.....	83
Figura 24: Diagrama UML de atividades da funcionalidade "Avaliar artefatos".....	84
Figura 25: Tela de exemplo para colocar uma pessoa na Rede de Confiança.....	85
Figura 26: Diagrama UML de atividades da funcionalidade "Colocar na Rede de Confiança". ....	86
Figura 27: Tela das recomendações recebidas pelo usuário, com a possibilidade de criticar as avaliações preditas.....	87
Figura 28: Diagrama UML de casos de uso das funcionalidades agregadas.....	88
Figura 29: Diagrama UML de classes representando a estrutura das funcionalidades agregadas ao ActivUFRJ.....	89
Figura 30: Representação da região de decisão do teste de hipóteses <i>Z</i> . ....	96

Figura 31: Método para avaliação do modelo.....	99
Figura 32: Número de avaliações feitas por usuários na base teste. Entre os usuários que fizeram avaliações, a média de avaliações por usuário é 43 e a mediana é 25. ....	100
Figura 33: Distribuição da quantidade de avaliações que o Usuário 1 possui com outros usuários, no total ele avaliou 137 filmes.....	101
Figura 34: Ocorrência de avaliações do mesmo filme por diferentes usuários.....	101
Figura 35: Dispersão das avaliações na base de dados Teste.....	102
Figura 36: Dispersão dos valores de avaliações dos usuários. ....	103
Figura 37: Correlação <i>Pearson R</i> do usuário 1 sobre todos os outros da base de dados. ....	105
Figura 38: Cobertura e <i>MAE</i> quando alterado o nível de <i>Pearson</i> .....	106
Figura 39: Cobertura e <i>MAE</i> quando alterado a quantidade de avaliações que influenciam na correlação entre dois usuários. ....	106
Figura 40: Cobertura e <i>MAE</i> quando alterado o número de pessoas que influenciam nas recomendações. ....	107
Figura 41: Estrutura da tabela de Rede de Confiança. A coluna transitividade representa em qual nível foi calculada a confiança, por exemplo, transitividade igual a 1 representa as confianças diretas do usuário. ....	110
Figura 42: Distribuição de confianças após utilização das características determinadas. ....	112
Figura 43. Algoritmo <i>K-Means</i> . Ilustração dos centros de agrupamento.....	115
Figura 44: Distribuição dos usuários por <i>Cluster</i> , onde os círculos representam os usuários. ....	116
Figura 45: Representação <i>Box-plot</i> das distâncias dos usuários para o centro do <i>cluster</i> que ele pertence. ....	118
Figura 46: Distribuição de avaliações dos participantes. ....	126
Figura 47: Distribuição de avaliações feitas pelos participantes para os filmes do experimento. ....	127
Figura 48: <i>Box-Plot</i> representando a forma de avaliar dos Participantes.....	132

## Lista de Equações

Equação 1: Correlação de <i>Pearson</i> entre dois usuários. ....	66
Equação 2: Predição da avaliação do item <i>i</i> para o usuário <i>a</i> .....	68
Equação 3: Fórmula para encontrar a confiança de um usuário <i>a</i> para um usuário <i>c</i> .....	70
Equação 4: Predição de avaliação pela confiança.....	71
Equação 5: <i>MAE</i> - Erro Absoluto Médio, cálculo da precisão da avaliação.....	95
Equação 6: Teste de hipóteses <i>Z</i> . ....	96
Equação 7: Confiança implícita pelo método da Cluster. ....	116

## Lista de Tabelas

---

Tabela 1: Pesquisas marcantes dos Sistemas de Recomendação.....	28
Tabela 2: Classificação das técnicas utilizadas em Sistemas de Recomendação. Adaptado de Adomavicius e Tuzhilin (2005). .....	42
Tabela 3: Matriz de avaliações.....	66
Tabela 4: Matriz de similaridades.....	66
Tabela 5: Lista de vizinhos dos usuários.....	67
Tabela 6: Recomendações para os usuários. ....	68
Tabela 7: Níveis de confiança contextualizada. ....	85
Tabela 8: Configuração da base de dados <i>MovieLens</i> após sua divisão em Teste e Treino. A coluna "Zeros" representa a porcentagem de filmes que não foram avaliados pelos usuários.....	99
Tabela 9: Teste de hipóteses Z para comparação de médias pelo método da Filtragem Colaborativa .....	109
Tabela 10: Resultados de cobertura e precisão da Filtragem Colaborativa tradicional.....	109
Tabela 11: Ajuste da correlação de <i>Pearson</i> para os fatores de confiança.....	111
Tabela 12: Teste de hipóteses Z para comparação de médias pelo método da Rede de Confiança. ....	113
Tabela 13: Resultados de cobertura e precisão do método da Rede de Confiança por <i>Pearson</i> ....	113
Tabela 14: Distribuição de usuários por <i>Cluster</i> . ....	116
Tabela 15: Exemplo da tabela de confiança entre usuários pelo <i>cluster K-means</i> .....	117
Tabela 16: Total de confianças por <i>cluster</i> . ....	117
Tabela 17: Distâncias entre centro dos <i>clusters</i> . ....	117
Tabela 18: Teste de hipóteses Z para comparação de médias pelo método do Cluster.....	119
Tabela 19: Resultados de cobertura e precisão do método da Rede de Confiança por <i>Cluster K-means</i> . ....	120
Tabela 20: Quadro comparativo da cobertura de usuários que receberam recomendações pelas três técnicas.....	121
Tabela 21: Quadro comparativo das três técnicas experimentadas quanto aos testes de cobertura, precisão <i>MAE</i> e teste de hipóteses Z. ....	121
Tabela 22: Distribuição dos filmes pela quantidade de avaliações recebidas. ....	126
Tabela 23: Distribuição de avaliações pela quantidade de estrelas que foi avaliado.....	127
Tabela 24: Distribuição de confianças diretas de todos os usuários.....	128
Tabela 25: Distribuição de confianças recebidas pelos usuários. ....	128
Tabela 26: Distribuição dos níveis de confiança realizados pelos usuários.....	129
Tabela 27: Resultados e dados gerais do experimento no ActivUFRJ.....	130
Tabela 28: Teste de hipóteses do experimento com o ActivUFRJ.....	134
Tabela 29: Resultados de cobertura e precisão das técnicas de recomendação empregadas nos experimentos.....	134

## Lista de siglas

---

ActivUFRJ	Ambiente Colaborativo de Trabalho Integrado e Virtual da UFRJ
ASP	<i>Active Server Pages</i>
AJAX	<i>Asynchronous Javascript and XML</i>
HTML	<i>HyperText Markup Language</i>
HTTP	<i>Hypertext Transfer Protocol</i>
IM	Instituto de Matemática
ISBN	<i>International Standard Book Number</i>
NCE	Núcleo de Computação Eletrônica
PLE	<i>Personal Learning Environments</i>
PPGI	Programa de Pós-Graduação em Informática
SBIE	Simpósio Brasileiro de Informática na Educação
SPSS	<i>Statistical Package for the Social Sciences</i>
SQL	<i>Structured Query Language</i>
UFRJ	Universidade Federal do Rio de Janeiro
UML	<i>Unified Modeling Language</i>
URL	<i>Universal Resource Locator</i>
WWW	<i>World Wide Web</i>

# Sumário

---

<b>1</b>	<b>INTRODUÇÃO</b>	<b>16</b>
1.1	Motivação e justificativas	17
1.2	Problema	18
1.3	Hipótese	18
1.4	Objetivos	19
1.5	Metodologia	20
1.6	Contribuições da pesquisa	21
1.7	Organização do texto	22
<b>2</b>	<b>SISTEMAS DE RECOMENDAÇÃO</b>	<b>24</b>
2.1	Introdução	25
2.2	Filtragem de informação	26
2.3	Sistemas de Recomendação	27
2.4	Pesquisas relacionadas	28
2.4.1	Filtragem Colaborativa	29
2.4.2	Sistemas de Recomendação	30
2.4.3	Sistemas de Reputação	31
2.4.4	Sistemas de Combinação Social	31
2.4.5	Tendências	32
2.5	Técnicas de filtragem aplicadas a Sistemas de Recomendação	35
2.5.1	Filtragem Baseada em Conteúdo	35
2.5.2	Filtragem Colaborativa	37
2.5.2.1	<i>Técnicas aplicadas na Filtragem Colaborativa</i>	38
2.5.3	Filtragem Híbrida	40
2.5.4	Técnicas aplicadas em pesquisas	41
2.6	Problemas em Sistemas de Recomendação	43
2.6.1	Problema do novo usuário	43
2.6.2	Problema do primeiro avaliador	44
2.6.3	Matrizes esparsas	44
2.6.4	Super-especialização do usuário	45
2.6.5	Problema do tipo de arquivo	45
2.7	Privacidade do usuário	45
2.8	Considerações finais	46
<b>3</b>	<b>REDES DE CONFIANÇA</b>	<b>47</b>
3.1	Definindo confiança	48
3.2	Rede de Confiança	50
3.2.1	Confiança explícita	51
3.2.2	Desconfiança	52

3.2.3	Propriedades da confiança .....	53
3.2.3.1	<i>Subjetiva</i> .....	53
3.2.3.2	<i>Assimétrica</i> .....	54
3.2.3.3	<i>Contextualizada</i> .....	54
3.2.3.4	<i>Transitiva</i> .....	55
3.2.4	Métricas de confiança.....	56
3.2.4.1	<i>Propagação direta</i> .....	57
3.2.4.2	<i>Confiança baseada na similaridade</i> .....	58
3.2.4.3	<i>Confiança Agregada</i> .....	58
3.3	Confiança em Sistemas de Recomendação.....	59
3.4	Considerações finais.....	61
<b>4</b>	<b>PROPOSTA DE SOLUÇÃO: RECOMENDAÇÃO BASEADA NA REDE DE CONFIANÇA DO USUÁRIO</b> .....	<b>62</b>
4.1	Descrição da proposta.....	63
4.2	Descrição do modelo.....	64
4.2.1	Etapa 1: Filtragem Colaborativa.....	65
4.2.1.1	<i>Correlacionar usuários</i> .....	65
4.2.1.2	<i>Filtrar vizinhos</i> .....	67
4.2.1.3	<i>Predição de avaliação</i> .....	67
4.2.2	Etapa 2: Rede de Confiança.....	68
4.2.2.1	<i>Confiança direta</i> .....	69
4.2.2.2	<i>Propagação da confiança</i> .....	69
4.2.2.3	<i>Prever avaliações</i> .....	70
4.2.3	Recomendação final de itens.....	71
4.2.4	Propriedades da confiança no modelo .....	72
4.3	Domínio de aplicação .....	72
4.4	Considerações finais.....	74
<b>5</b>	<b>ESPECIFICAÇÃO E IMPLEMENTAÇÃO DO PROTÓTIPO</b> .....	<b>76</b>
5.1	Introdução .....	77
5.2	Visão geral do ActivUFRJ.....	77
5.2.1	Estrutura base do ActivUFRJ.....	78
5.2.2	Minha página.....	78
5.2.3	Página do usuário.....	79
5.2.4	Página da comunidade .....	80
5.2.5	Página do artefato.....	81
5.2.6	Tecnologias utilizadas no ActivUFRJ.....	82
5.3	O Protótipo: Funcionalidades agregadas .....	83
5.3.1	Avaliação de artefato.....	83
5.3.2	Rede de Confiança.....	84
5.3.3	Recomendações geradas .....	87
5.4	Estrutura do protótipo .....	88

5.4.1	Diagrama de classes.....	89
5.4.2	Casos de uso.....	89
5.5	Considerações finais.....	91
<b>6</b>	<b>EXPERIMENTOS E RESULTADOS.....</b>	<b>92</b>
6.1	Descrição dos experimentos.....	93
6.1.1	Métricas para avaliação das recomendações.....	94
6.1.1.1	<i>Cobertura</i> .....	94
6.1.1.2	<i>Precisão da predição</i> .....	94
6.1.1.3	<i>Teste de Hipóteses Z</i> .....	95
6.2	Estudo 1: Validação do modelo.....	97
6.2.1	Base de dados experimental.....	97
6.2.2	Avaliação da base de dados Teste.....	99
6.2.3	Experimentos realizados.....	103
6.2.3.1	<i>Experimento 1: Filtragem Colaborativa tradicional (Pearson R)</i> .....	103
6.2.3.2	<i>Experimento 2: Redes de confiança direta (Pearson)</i> .....	109
6.2.3.3	<i>Experimento 3: Redes de confiança direta (Cluster K-means)</i> .....	114
6.2.4	Conclusões do Estudo 1.....	120
6.2.5	Limitações dos experimentos.....	123
6.3	Estudo 2: O Protótipo ActivUFRJ.....	123
6.3.1	Detalhamento do estudo de caso.....	124
6.3.2	Organização do estudo.....	124
6.3.3	Coleta de dados.....	125
6.3.4	Resultados.....	129
6.3.5	Limitações do modelo.....	135
6.3.6	Comentários dos participantes.....	136
6.4	Conclusões.....	137
<b>7</b>	<b>CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS.....</b>	<b>139</b>
7.1	Resumo do trabalho.....	140
7.2	Contribuições da Dissertação.....	141
7.3	Trabalhos futuros.....	142
	<b>REFERÊNCIAS.....</b>	<b>145</b>
	<b>ANEXO A - CÓDIGOS DO MATLAB.....</b>	<b>154</b>
	<b>ANEXO B – CONVITE PARA O EXPERIMENTO.....</b>	<b>162</b>
	<b>ANEXO C – QUESTIONÁRIO DO EXPERIMENTO.....</b>	<b>164</b>

# Capítulo 1

## Introdução

---

"A corrida para excelência não tem linha de chegada."

*David Rye*

Neste capítulo é apresentada sucintamente a pesquisa documentada nesta dissertação, abordando as motivações e justificativas, o problema e a hipótese de pesquisa, os objetivos da dissertação, a metodologia utilizada e a organização do texto.



## 1.1 Motivação e justificativas

Na sociedade atual, todos necessitam de informações para realizar suas atividades diárias, sejam estas para tarefas profissionais ou pessoais. Nesse sentido, a Internet se tornou um meio poderoso para facilitar a busca por informação, por ser um local onde todos podem expressar suas opiniões, interesses e experiências. O grande desafio está em encontrar informações realmente relevantes e confiáveis, frente à sobrecarga de informação ocasionada pela crescente quantidade de informações existente na Internet.

Nesse contexto, as comunidades virtuais e os Sistemas de Recomendação têm sido utilizados com sucesso para auxiliar os usuários na procura por informações relevantes. As comunidades virtuais têm possibilitado que pessoas, de todos os lugares e formações, possam se encontrar virtualmente para trocar experiências em torno de assuntos, interesses, vontades, comportamento e atitudes comuns em relação a algum tema.

Já os Sistemas de Recomendação atuam baseados em personalização da informação, que está relacionada com o modo pelo qual a informação e os serviços podem ser ajustados às necessidades específicas de um usuário ou comunidade, possibilitando uma maior eficiência no processo de encontrar informações relevantes em menor espaço de tempo.

Nesse sentido, o Sistema de Recomendação, quando agregado em comunidades virtuais, pode utilizar as informações compartilhadas por todos os usuários da comunidade para prover, colaborativamente, recomendações personalizadas e confiáveis. Além disso, comunidades virtuais atuais (*orkut.com*, *linkedin.com*, *friendster.com*, etc.) permitem a formação de redes sociais de relacionamentos, com a possibilidade de julgamento de confiança entre usuários, criando as Redes de Confiança.

Sendo assim, a principal motivação para essa pesquisa é utilizar a Rede de Confiança do usuário, relacionada a contextos específicos, visando facilitar a identificação dos interesses dos

usuários, auxiliando assim o Sistema de Recomendação a realizar o casamento correto entre os que estão recomendando e aqueles que estão recebendo a recomendação.

## 1.2 Problema

Os Sistemas de Recomendação vêm se apresentando como uma ótima solução para reduzir o problema de sobrecarga de informações, em especial a técnica de Filtragem Colaborativa, que automatiza o processo de recomendações, baseando-se somente nas opiniões dos usuários sobre itens de uma comunidade.

Porém, a Filtragem Colaborativa apresenta algumas limitações, entre elas: o problema do novo usuário (*cold start user*), matrizes esparsas e o problema do novo item, detalhados no Capítulo 2.

O problema do novo usuário refere-se ao fato de que quando um usuário novo entra na comunidade, o sistema não tem nenhuma informação sobre o perfil dele e, com isso, não consegue gerar recomendações para ele. O grande desafio está no tempo que o sistema precisa para ter informações suficientes do novo usuário. Estratégias de recomendação não personalizada podem encurtar esse tempo, porém têm o risco de deixar o usuário insatisfeito.

Dessa forma, no contexto dessa dissertação, pretende-se investigar a seguinte questão:

“Como desenvolver um Sistema de Recomendação de itens em uma comunidade para que os problemas relativos à Filtragem Colaborativa sejam minimizados, em especial o problema do novo usuário?”

## 1.3 Hipótese

No mundo real a recomendação de produtos, serviços ou qualquer tipo de item constitui-se em uma prática muito antiga, podendo ser feita através da recomendação boca-a-boca (*word-of-mouth*) (RESNICK e VARIAN, 1997; SHARDANAND e MAES, 1995). Na Internet essa prática se apresenta com os Sistemas de Recomendação. Este tipo de sistema deve

aprender sobre o usuário do sistema para então poder recomendar produtos, serviços ou qualquer outro tipo de item (RESNICK e VARIAN, 1997). Em especial, os Sistemas de Recomendação pela Filtragem Colaborativa, utilizam o perfil do usuário para encontrar pessoas similares a ele, para então, recomendar itens que possam ser de interesse do usuário.

Uma prática que vem se tornando comum na Internet é a formação de comunidades virtuais de interesse, e dentro dessas comunidades, os participantes podem estabelecer suas confianças em outros indivíduos. Essa confiança não vem sendo utilizada no sentido de auxiliar a recomendação boca-a-boca, descrito anteriormente, porém tem um potencial de descoberta de similaridade entre indivíduos muito maior que a Filtragem Colaborativa, já que, os indivíduos confiáveis são escolhidos explicitamente por quem receberá as recomendações.

Dessa forma, com base na questão de pesquisa dessa dissertação, foi formulada a seguinte hipótese:

“Utilizando a rede de confiança do usuário, é possível gerar recomendações mais confiáveis e fazer com que novos usuários comecem a receber recomendações mais rapidamente.”

## 1.4 Objetivos

Esta dissertação tem como objetivo principal utilizar a confiança do usuário, em outros usuários, para minimizar os problemas inerentes aos Sistemas de Recomendação dentro de uma comunidade virtual, dando uma maior ênfase ao problema do novo usuário. Além disso, contribuindo para a área de Sistemas de Recomendação de itens com um modelo de recomendação baseado na confiança do usuário.

Objetivos específicos:

1. Criação de um modelo de recomendação para minimizar os problemas comuns de Sistemas de Recomendação;
2. Implementação de um protótipo para validação do modelo;

3. Experimentação e análise do modelo.

## 1.5 Metodologia

Diversos procedimentos orientaram a realização dessa pesquisa científica, nessa seção são apresentados os principais momentos, bem com as estratégias adotadas para que fosse possível a conclusão dessa dissertação.

A primeira etapa compreendeu a realização de uma revisão bibliográfica em livros e artigos e em entrevistas informais com alguns especialistas, no sentido de obter a fundamentação teórica necessária para essa pesquisa.

Outra etapa importante foi o desenvolvimento de um protótipo, o qual abrangeu todas as fases de desenvolvimento de um sistema, ou seja, as fases de levantamento dos requisitos, especificação, modelagem e descrição da ferramenta, codificação, prototipagem, implementação e validação.

Durante a realização dessa pesquisa, dois estudos foram fundamentais para validação do modelo proposto, cada estudo foi conduzido baseado nos seguintes objetivos:

- Estudo 1: O primeiro estudo teve como objetivo principal validar o modelo proposto. Para isso, foram conduzidos 3 estudos de caso utilizando uma base de dados real, com milhares de dados históricos, para avaliar a viabilidade do modelo proposto. Esse estudo foi conduzido a partir da análise *off-line* dos dados, sem participação de usuários.
- Estudo 2: O segundo estudo foi utilizado para validação final da proposta com a participação direta de um grupo de pessoas em um protótipo desenvolvido na comunidade virtual ActivUFRJ. Os processos metodológicos conduzidos nesse segundo estudo envolvem a implementação, aplicação do modelo e a análise de um questionário aplicado aos participantes.

Esses estudos, detalhados no Capítulo 6, foram fundamentais para coleta e interpretação dos dados, a fim de avaliar o protótipo desenvolvido e verificar a viabilidade da hipótese que orienta essa dissertação.

## 1.6 Contribuições da pesquisa

As principais contribuições dessa dissertação com relação a Sistemas de Recomendação são:

- A apropriação da confiança do usuário como fator importante para gerar recomendações;
- A possibilidade de integração mais rápida de novos usuários na comunidade, um problema relativo a Sistemas de Recomendação pela Filtragem Colaborativa, onde o usuário precisa avaliar vários itens para começar a receber recomendações. Este trabalho apresenta um modelo que possibilita aos usuários novos na comunidade receberem recomendações com apenas uma indicação de confiança;
- A apresentação de um modelo de Sistema de Recomendação baseado na confiança do usuário;
- A indicação de caminhos para aprofundamento de pesquisas com Sistemas de Recomendação utilizando Redes de Confiança dos usuários;
- A especificação e implementação de um protótipo integrado à comunidade virtual ActivUFRJ, possibilitando a ampliação da proposta e o desenvolvimento de novas pesquisas;
- A apresentação dos resultados obtidos a partir de dois estudos que contribuíram para verificar a viabilidade da solução apresentada para o problema da dissertação e que podem servir como base para a realização de novos estudos e trabalhos futuros.

## 1.7 Organização do texto

Este documento está organizado da seguinte forma:

- No Capítulo 2 - Sistemas de Recomendação: é feita uma breve introdução de Sistemas de Recomendação, as pesquisas relacionadas, técnicas para recomendar e apresentados os problemas associadas à Filtragem Colaborativa.
- No Capítulo 3 - Redes de Confiança: é feita uma introdução sobre redes de confiança, as maneiras possíveis para propagar a confiança e são apresentadas algumas aplicações que utilizam redes de confiança em Sistemas de Recomendação.
- O Capítulo 4 - Proposta de Solução: Recomendação Baseada na Rede de Confiança, apresenta o modelo desenvolvido para recomendar itens com base na confiança do usuário, seguido de um exemplo prático utilizado de aplicação do modelo proposto nesta tese.
- No Capítulo 5 - Especificação e Implementação do Protótipo, a estrutura do protótipo é apresentado e são descritos as funcionalidades que foram agregadas ao ActivUFRJ, para avaliar o modelo experimentalmente. Inicialmente nesse capítulo é feita uma introdução ao ActivUFRJ e suas funcionalidades.
- A avaliação do modelo do Capítulo 4 é apresentada no Capítulo 6 - Experimentos e Resultados. Foram desenvolvidos dois Estudos objetivando validar o modelo, utilizando métricas de cobertura e precisão.
- As conclusões e trabalhos futuros são apresentados no Capítulo 8 – Considerações Finais e Trabalhos Futuros, seguidas das Referências e dos Anexos.

A Figura 1 apresenta graficamente a organização dessa dissertação em capítulos.

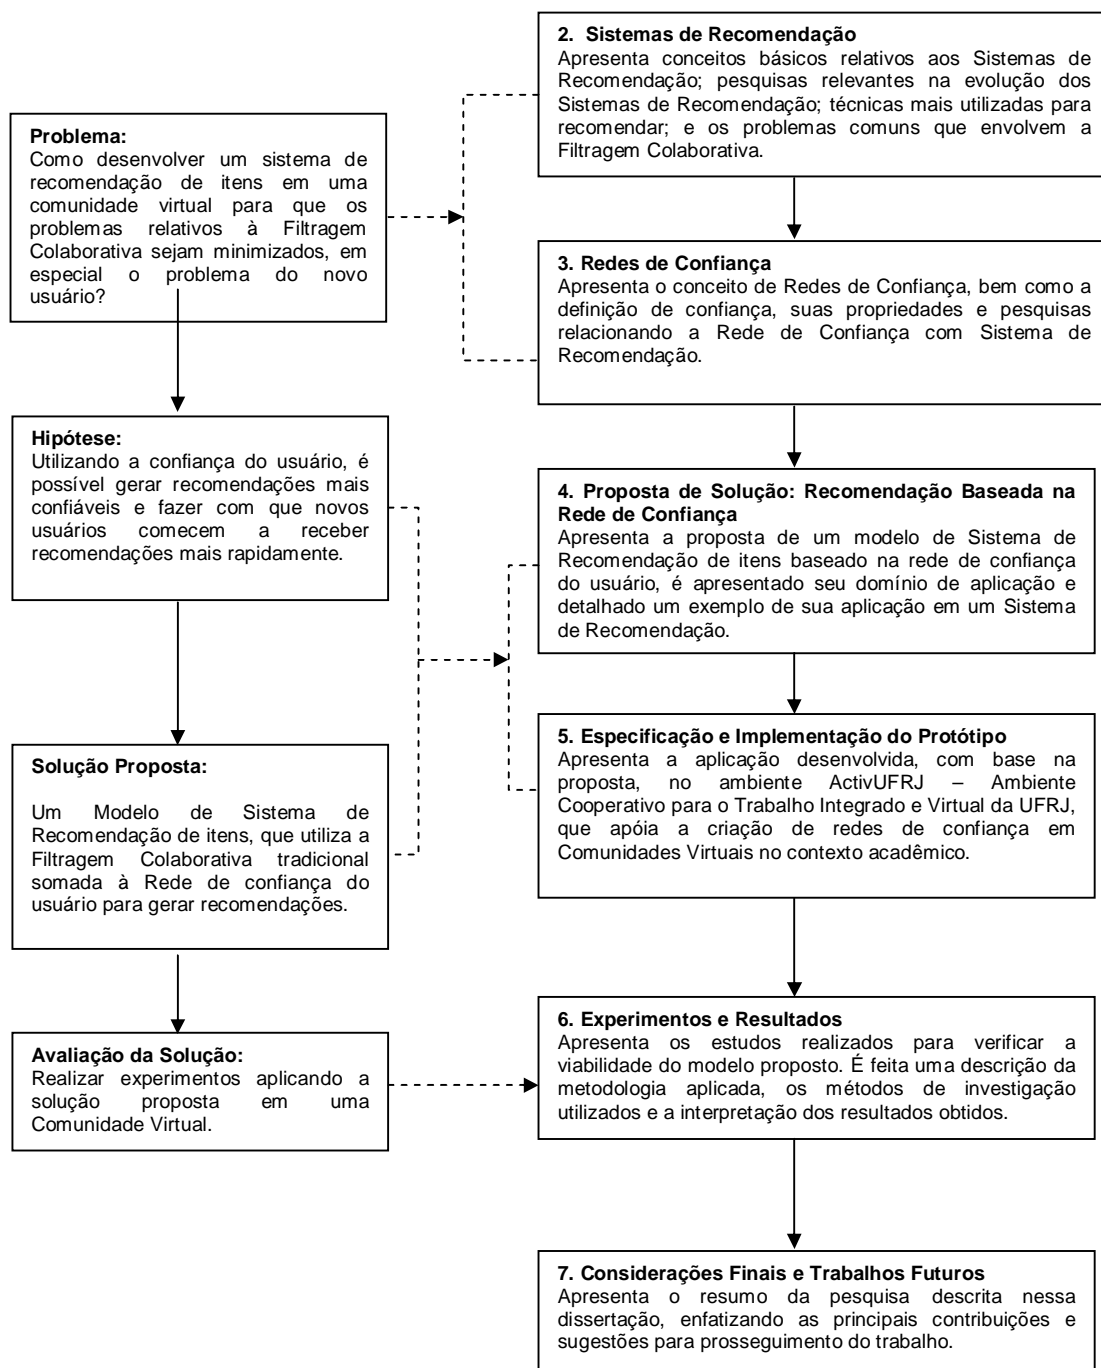


Figura 1: Organização da dissertação em capítulos.

## Capítulo 2

# Sistemas de Recomendação

---

“Comece fazendo o que é necessário, depois o que é possível, e de repente você estará fazendo o impossível.”

*São Francisco de Assis*

Neste Capítulo é feita uma introdução de Sistemas de Recomendação. Para isso, inicialmente é apresentada sua evolução no tempo pelas pesquisas relevantes da área, suas técnicas principais para aplicação, bem como a identificação dos problemas mais comuns dos Sistemas de Recomendação.



## 2.1 Introdução

Sistemas de Recomendação vêm sendo usado amplamente na Internet, com o objetivo principal de auxiliar os usuários a encontrar informações de seu interesse. Em um Sistema de Recomendação comum, pelo menos três passos são necessários:

- i. Usuários provêm informações com exemplos de seus gostos e interesses, que podem ser explícitos, como avaliações sobre itens, ou implícitos, como páginas visitadas pelo usuário (RESNICK e VARIAN, 1997);
- ii. Esses exemplos são utilizados para criar o perfil do usuário, uma representação do que o usuário gosta e não gosta;
- iii. O sistema gera as recomendações a partir do perfil criado do usuário.

As recomendações podem ser geradas através de três técnicas (RESNICK *et al.*, 2000): Filtragem Colaborativa, Filtragem Baseada em Conteúdo e Filtragem Híbrida, que integram as duas abordagens. Dentre elas, a Filtragem Colaborativa, que utiliza o histórico do usuário, é a mais utilizada de acordo com Resnick *et al.* (2000) e Massa *et al.* (2004). Mais detalhes dessas técnicas são apresentados na Seção 2.5.

Os Sistemas de Recomendação são definidos, segundo Resnick e Varian (1997), como sistemas que auxiliam e aumentam a eficácia do processo natural de recomendações “boca-a-boca” de livros, filmes, restaurantes, etc. Através destes sistemas é possível recomendar, aos usuários, produtos de uma determinada categoria, baseando-se no conhecimento e utilizações prévias (compras, navegação, mensagens, etc.) de outras pessoas presentes no sistema.

Pode-se dizer que, Sistema de Recomendação é uma tecnologia, de filtragem de informação personalizada, usada para predizer quais ou quantos itens que um usuário poderia se interessar. Nos últimos anos, Sistemas de Recomendação têm sido usados em muitas aplicações (SHARDANAND e MAES, 1995; HILL *et al.*, 1995; KONSTAN *et al.*, 1997; TERVEEN *et al.*, 1997; SCHAFER *et al.*, 1999; KITTS *et al.*, 2000; MOBASHER *et al.*, 2000). Como exemplos de

estratégias adotadas para recomendação, têm-se: a recomendação de produtos que um usuário poderia comprar; filmes ou músicas que gostaria de assistir ou ouvir; e até mesmo sugerindo maneiras alternativas para procurar informações em sistemas de busca.

Com os avanços das pesquisas, diferentes informações dos usuários foram utilizadas para gerar as recomendações, entre elas: dados demográficos, conteúdo dos itens, histórico de navegação do usuário, entre outras (TERVEEN *et al.*, 1997; KONSTAN *et al.*, 1997; SHARDANAND e MAES, 1995).

## 2.2 Filtragem de informação

Se o problema é que as pessoas estão sobrecarregadas de informação, a solução que parece mais interessante é filtrar as informações para que somente conteúdos interessantes e relevantes apareçam para o usuário. Muitos sistemas de filtragem atuais são baseados em construir um perfil de usuário a partir do conteúdo das informações que o usuário teve acesso. Estes sistemas tentam extrair padrões do comportamento do usuário para prever quais informações seriam relevantes ou irrelevantes para ele.

Segundo Foltz (1992) e Herlocker (2000) as aplicações de filtragem de informação envolvem tecnologias de consulta e indexação baseadas na análise do conteúdo do item, essencialmente para documentos textuais. Indexar pode ser descrito como o processo de examinar coleções de conteúdos e criar uma estrutura de dados que contenha descrições dos itens avaliados. Uma das questões-chave neste processo está na identificação do que é realmente importante e do que é irrelevante, sendo que retirar o irrelevante é fundamental. A identificação de termos relacionados também é importante para que não ocorra perda de conteúdo dito relevante. Por exemplo, caso seja solicitada a filtragem de informações relacionadas com o assunto "Sistemas de Recomendação", seria importante recuperar conteúdos, por exemplo, referentes à "Filtragem Colaborativa".

Os sistemas de filtragem de informação são uma ótima solução para os usuários que sabem realmente o que desejam buscar, porém muita informação pode ser perdida pelo fato do usuário não ter conhecimento de outros conteúdos que também seriam interessantes.

## 2.3 Sistemas de Recomendação

Com a quantidade de informações e com a disponibilidade facilitada das mesmas pelo uso da Internet, as pessoas se deparam com uma diversificação muito grande de opções. Muitas vezes uma pessoa não possui nenhuma, ou quase nenhuma, experiência pessoal para realizar escolhas entre as várias alternativas que lhe são apresentadas durante uma busca por informações.

A questão relevante neste momento refere-se a como proceder nestes casos. Para minimizar as dúvidas e necessidades que temos frente à escolha entre alternativas, geralmente confiamos nas recomendações que são passadas por outras pessoas, as quais podem chegar de forma direta “boca-a-boca” (*word of mouth*) (SHARDANAND e MAES, 1995), cartas de recomendação, opiniões de revisores de filmes e livros, impressos de jornais, entre outras.

Os Sistemas de Recomendação já não são novidade na aplicação em empresas e na Internet. Tradicionalmente, os Sistemas de Recomendação lidam com aplicações que juntam dois tipos de entidades: usuários e itens. Resnick e Varian (1997) definem Sistemas de Recomendação como sistemas que utilizam as opiniões de uma comunidade de usuários para auxiliar indivíduos desta mesma comunidade a identificarem conteúdos de interesse em um conjunto de opções que poderiam caracterizar uma sobrecarga.

Os Sistemas de Recomendação auxiliam no aumento da capacidade e da eficácia deste processo de indicação já bastante conhecido na relação social entre seres humanos (RESNICK e VARIAN, 1997). Segundo Schafer (1999) os Sistemas de Recomendação são usados pelos *sites* de comércio eletrônico para sugerir produtos para seus clientes e fornecer informações que procuram auxiliar os clientes sobre qual produto deve ser adquirido.

## 2.4 Pesquisas relacionadas

Durante os últimos anos surgiram várias pesquisas com o objetivo de filtrar a enorme quantidade de informação produzida diariamente na Internet. Algumas dessas pesquisas foram marcantes na evolução da filtragem de informação para os Sistemas de Recomendação como conhecido atualmente. Tendo em vista essa grande evolução, na Tabela 1 foram selecionadas algumas dessas pesquisas.

**Tabela 1: Pesquisas marcantes dos Sistemas de Recomendação.**

Tempo	Pesquisas marcantes e exemplos	Características
1992	<b>Filtragem Colaborativa</b> <i>Tapstry</i> (GOLDBERG <i>et al.</i> , 1992)	Usuários interagem com algoritmos para receber recomendações. Recomendação não personalizada.
1994	<b>GroupLens</b> (RESNICK <i>et al.</i> , 1994)	Sistemas utilizam dados históricos de outros usuários para gerar as recomendações. Mas os dados não são acessíveis aos usuários. Centralização na busca por informação ou venda de produtos.
1995	<b>Ringo/Firefly</b> (SHARDANAND e MAES, 1995) <b>UsenetNews</b> (MALTZ e EHRLICH, 1995)	
1997	<b>Sistemas de Recomendação</b> (RESNICK e VARIAN, 1997) <b>Redes Sociais - Referral Web</b> (KAUTZ <i>et al.</i> , 1997). Ex. <i>Amazon.com</i>	Recomendação personalizada para cada usuário.
2000	<b>Sistemas de Reputação</b> (RESNICK <i>et al.</i> , 2000) Ex. <i>Epinions.com</i>	Utilização da experiência do usuário na comunidade influenciando na relevância da sua opinião, e essa relevância utilizada para recomendar informações.
2005	<b>Sistemas de Combinação Social</b> (TERVEEN e MCDONALD, 2005) <b>Redes de confiança</b> (MASSA <i>et al.</i> , 2005) Ex. <i>Last.fm</i> , <i>Del.icio.us</i>	Construção de redes sociais. Usuários interagem com outros usuários, o conteúdo deles e <i>tags</i> para encontrar informação ou conectar com pessoas. Informações baseadas em <i>tags</i> . Informações de outras pessoas expostas e atualizadas em tempo real.
Tendência	Ex. <i>Google Maps</i> , <i>LivePlasma</i>	Foco na interação do usuário, com interface simples, amigável e acessível. Recomendação transparente, usuário tem controle das recomendações que recebe. Fidelização de usuários através de melhores recomendações. Foco na vida social do usuário.

Com essa tabela, pode-se ver que até 2000 o foco da filtragem de informação estava na informação propriamente dita, e a partir de 2005 os esforços para as técnicas de recomendação passaram a focar no usuário. Nesse sentido, o usuário passou de apenas consumidor para colaborador de informações, provendo dados de seus gostos e preferências, e esses dados sendo utilizados para auxiliar no processo de recomendação de informações relevantes para outros usuários.

A seguir, são apresentados os principais conceitos relacionados aos Sistemas de Recomendação, bem como as principais pesquisas que marcaram a evolução dos Sistemas de Recomendação.

### 2.4.1 Filtragem Colaborativa

De acordo com Resnick *et al.* (1994), o termo Filtragem Colaborativa surgiu com os desenvolvedores do primeiro Sistema de Recomendação, *Tapestry* (GOLDBERG *et al.*, 1992). Nessa pesquisa, a Filtragem Colaborativa era referenciada como pessoas colaborando, com avaliações sobre os documentos lidos, com o objetivo de ajudar outras pessoas na filtragem de informação.

Com isso, a Filtragem Colaborativa se tornou um marco para os Sistemas de Recomendação, onde os usuários passaram a colaborar com os sistemas para serem beneficiados com recomendações a partir das informações que os próprios usuários forneciam ao ambiente. Outros projetos, com destaque para *Ringo* (SHARDANAND e MAES, 1995), *UsenetNews* (MALTZ e EHRLICH, 1995) e *GroupLens* (Resnick *et al.*, 1994), trouxeram novas discussões e contribuições nessa fase de evolução da filtragem da informação.

## 2.4.2 Sistemas de Recomendação

Resnick e Varian (1997) cunharam o termo Sistema de Recomendação no contexto da filtragem de informação ao editarem a revista CACM<sup>1</sup> 1997. Nessa pesquisa era sugerido que a Filtragem Colaborativa devia ser tratada com um termo mais geral, como Sistemas de Recomendação, já que, quem recebe a recomendação não colabora explicitamente com os usuários da comunidade e as recomendações sugerem itens com interesses particulares de cada usuário.

Dentre as pesquisas que foram marcantes para a abordagem Resnick e Varian (1997) com o projeto *GroupLens*, surgiu com a idéia de auxiliar pessoas a encontrar artigos de interesse em um grande volume de artigos ofertados. O *GroupLens* apresentou um novo mecanismo para auxiliar na descoberta de informações relevantes para cada pessoa, sua essência baseava-se na idéia que as pessoas que avaliam artigos de forma similar no passado tendem a concordar nas avaliações no futuro. A principal novidade trazida por esse projeto foi gerar recomendações prevendo o quanto o usuário que está recebendo recomendações avaliaria o artigo se tivesse lido, outra novidade estava no fato das recomendações serem geradas sem a solicitação do usuário.

Quem mais ganhou com essa técnica, foram os sistemas de comércio eletrônico, que se apropriaram dos Sistemas de Recomendação com foco na recomendação de produtos que os consumidores pudessem se interessar, e conseqüentemente, comprar. Com isso, os *sites* de comércio eletrônico (*Amazon.com*, *Epinions.com*, *Ebay.com*, *Submarino.com.br*, dentre outros) vêm sendo um dos principais responsáveis na evolução de técnicas para recomendar e nas estratégias de apresentação das recomendações.

---

<sup>1</sup> *Communication of the ACM 1997*

### 2.4.3 Sistemas de Reputação

De acordo com Resnick *et al.* (2000), os Sistemas de Reputação representam uma importante alternativa de auxiliar os usuários a criarem relacionamentos confiáveis na Internet, permitindo que eles realizem avaliações pessoais sobre a atuação dos indivíduos, e identifiquem as reputações avaliadas perante a opinião de uma comunidade. Dessa forma, esses sistemas apresentam mecanismos para promover e gerenciar relações de confiabilidade entre usuários de ambientes de interação virtual.

Com esse foco surgiu o *Epinions*, uma comunidade virtual onde os participantes inserem revisões sobre os mais diversos produtos e suas revisões são avaliadas pelos membros da comunidade. Ele segue a idéia de que quanto melhor forem avaliadas as revisões do usuário, melhor será sua reputação perante a comunidade. Os sistemas de reputação também são muito utilizados em sites de leilões (*eBay.com*, *MercadoLivre.com*), que possibilitam usuários se encontrarem para compra e venda de qualquer produto na Internet, e compradores precisam confiar em vendedores e vice-versa, mesmo que nunca tenham negociado antes.

### 2.4.4 Sistemas de Combinação Social

De acordo com Terveen e McDonald (2005), Sistemas de Combinação Social surgiram da possibilidade de encontrar pessoas que compartilhem de interesses similares, identificando similaridades demográficas entre os usuários (aparência, sexo, idade, localização, grau de instrução, interesses, etc.) a partir das redes sociais de relacionamentos formadas através de comunidades virtuais, Sistemas de Recomendação, e da grande variedade de atividades sociais que os usuários desempenham ao mesmo tempo, todos os dias.

Os usuários geralmente criam uma expectativa de encontrar seus pares enquanto participam de comunidades virtuais, ou interagem com outras pessoas em listas de discussão, *blogs*, fóruns, salas de bate papo e *instant messaging*. Entretanto, de acordo com Terveen e

McDonald (2005), Sistemas de Combinação Social também podem aproximar pessoas enquanto elas realizam atividades que são executadas de forma solitária, como por exemplo: checagem de *e-mails* pessoais, compras, navegação e pesquisa na *Web*. Pode-se dizer que a Combinação Social é um Sistema de Recomendação de Pessoas.

*ReferralWeb* (KAUTZ *et al.*, 1997), foi um dos ambientes pioneiros da Combinação social, ao trazer inovações na abordagem de Sistemas de Recomendação trabalhando com redes sociais, sua idéia era que através de um ambiente virtual fosse possível gerenciar e visualizar redes sociais para auxiliar na busca de pessoas ou informações. O *ReferralWeb* recomenda autores de artigos relacionados ao assunto de interesse do requisitante, que estejam mais próximos dele pela sua rede social. Outro sistema que surgiu com essa idéia foi o *Expertise Recommender* (MCDONALD e ACKERMAN, 2000), que utiliza redes sociais para auxiliar a localização de especialistas em determinado assunto dentro de uma empresa.

Muitos portais de comunidades virtuais atualmente disponíveis apresentam diferentes propostas para recomendação de pessoas, como por exemplo: formar grupos de pessoas com interesses profissionais nos mesmos assuntos (*Syxt.com.br*, *LinkedIn.com*), ou grupos de pessoas que procuram reencontrar velhos amigos, fazer novas amizades, ou encontrar parceiros de afinidades e atividades (*Orkut.com*, *Friendster.com*).

### 2.4.5 Tendências

Como se pode ver, os Sistemas de Recomendação estão evoluindo no sentido de possibilitar uma maior interação dos usuários com as recomendações e com o próprio sistema. Isso vem se tornando uma tendência não apenas para os Sistemas de Recomendação, como em outras aplicações para Internet que vêm possibilitando e incentivando os usuários a serem produtores de conhecimento e não apenas consumidores de informações.



O aparecimento da *Web2.0* (O'REILLEY, 2005) está tornando a Internet um ambiente cada vez mais personalizado e colaborativo, onde o usuário pode adaptar interfaces às suas necessidades pessoais.

No contexto de recomendação de filmes, o *LivePlasma* ([www.liveplasma.com](http://www.liveplasma.com)) apresenta uma forma inovadora de apresentar indicações de filmes e músicas que possam interessar ao usuário, basta que o usuário faça a busca de um filme para o sistema montar uma rede de esferas interligadas com filmes relacionados, que podem ser de interesse do usuário, conforme a Figura 2. Essa rede é montada com base no motor de recomendações da *Amazon.com* e com indicações de preferências dos usuários dentro da própria comunidade.

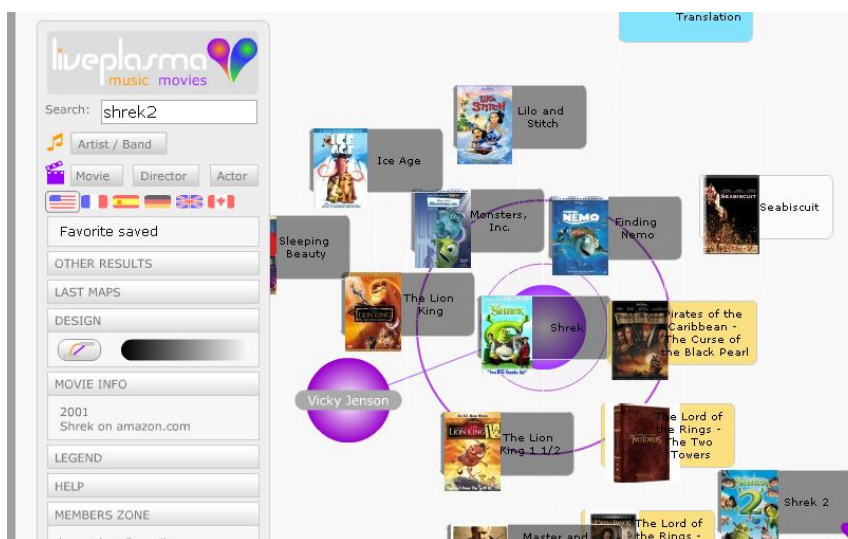


Figura 2: Sistema de Recomendação de filmes, tela do Liveplasma.com.

Além disso, a *Web2.0* incentiva o usuário a exercer sua capacidade de opinar, criando *tags* classificatórias e associando aos conteúdos da *Web* (*folksonomy*) (WU *et al.*, 2006). Nesse sentido, surgiram comunidades virtuais que potencializam a interação dos usuários, sugerindo recomendações através das *tags* criadas pela comunidade (*del.icio.us*, *Flickr.com*, etc.).

No contexto de recomendação de músicas, o *Last.fm* se apoiou nos conceitos das *tags* para criar uma comunidade virtual onde são trocadas informações e recomendações sobre artistas e músicas. O *Last.fm* constrói um perfil público detalhado do gosto musical de cada usuário,

mostrando suas músicas e artistas favoritos. O perfil de todos os usuários da comunidade é utilizado para: criar listas de artistas parecidos, músicas mais tocadas, grupos de pessoas com interesses similares, para gerar recomendações personalizadas, entre outras. A Figura 3 mostra uma tela do *Last.fm* que apresenta a lista de artistas parecidos com o artista "Zeca Baleiro".



The screenshot shows the Last.fm website interface. At the top, there is a navigation bar with links for "Música", "Usuários", "Ouvir", and "Eventos". Below this, there is a search bar and a "Procurar música" button. The main content area is titled "Zeca Baleiro" and features a profile picture of the artist. To the right of the profile, there is a section titled "Artistas parecidos" (Similar Artists) which displays a list of artists with their respective profile pictures and a numerical value representing their similarity score. The list includes:

Artista	Nota
Lenine	100
Cássia Eller	98
Cordel do Fogo Encantado	79
Los Hermanos	79
Marisa Monte	78
Nando Reis	77
Cazuza	74
Paulinho Moska	73
Engenheiros do Hawaii	71
Pato Fu	71
Adriana Calcanhoto	68

Figura 3: Sistema de Recomendação de músicas, tela do last.fm.

Nesse sentido de apoiar a colaboração dos usuários, a *Web2.0* também incentiva os usuários a atuar como revisores e formadores de opinião através da avaliação de produtos e serviços. Essa situação, está presente em muitos *sites* de comércio eletrônico (*amazon.com*, *submarino.com.br*, etc.), onde as opiniões dos usuários são utilizadas para dar credibilidade ao produto que está sendo vendido. Porém, outros ambientes virtuais (*wikipedia.org*, etc.) vêm utilizando essa colaboração dos usuários como forma de reputação de produtos ou serviços oferecidos.

O *GoogleMaps* (*maps.google.com*) é um sistema de busca e visualização de mapas, porém com ele é possível encontrar empresas, hotéis, bares ou qualquer tipo de serviço. A colaboração dos usuários nesse ambiente é importante para inserir novos serviços e para avaliar os serviços utilizados. Por exemplo, um usuário que se hospedou em uma Pousada no Rio de Janeiro, pode fazer uma resenha sobre essa Pousada, inserindo fotos, vídeos e informações que julgue relevante

alertar para que outros usuários, com interesse em se hospedarem na mesma Pousada, conforme a Figura 4.

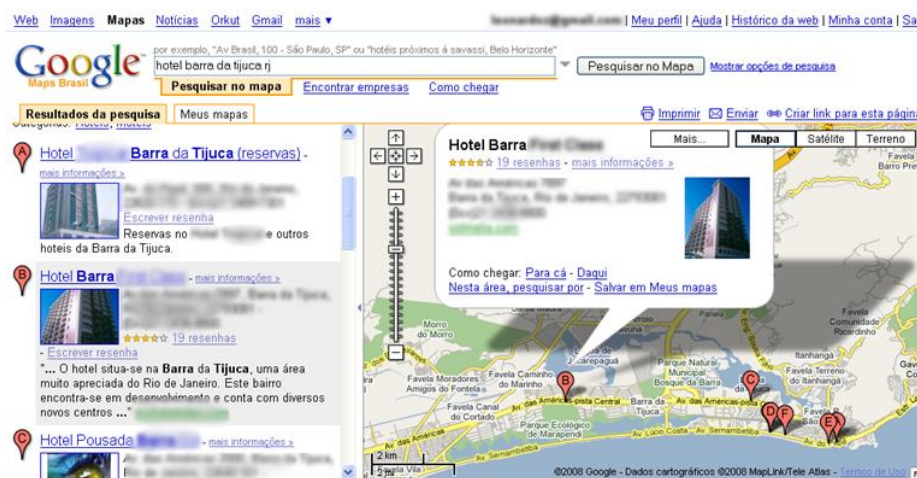


Figura 4: Sistema de Recomendação de serviços, tela do *GoogleMaps*.

A seguir são apresentadas as técnicas mais utilizadas para gerar recomendações.

## 2.5 Técnicas de filtragem aplicadas a Sistemas de Recomendação

A seguir são descritas três técnicas aplicadas a Sistemas de Recomendação, segundo o autor Herlocker (2000): a Filtragem Baseada em Conteúdo, a Filtragem Colaborativa e a Filtragem Híbrida.

### 2.5.1 Filtragem Baseada em Conteúdo

A Filtragem Baseada em Conteúdo utiliza as descrições de um determinado item, bem qualificado pelo usuário, para recomendar um item que seja similar ao item. Tenta assim, identificar similaridade pelas diversas características do item (por exemplo, no contexto de filmes, atores específicos, gêneros, diretores, descrição, etc.), para que então, os itens que tiverem maior grau de similaridade, sejam recomendados ao usuário.

A Filtragem Baseada em Conteúdo tem suas raízes na recuperação de informação (SALTON, 1989) e filtragem de informação (BAEZA-YATES, 1999). Muitos Sistemas de

Recomendação atuais baseados em conteúdo focam na recomendação de informações textuais, como documentos, *sites*, *blogs*, fóruns, etc. A melhoria sobre os sistemas tradicionais de recuperação de informação está na utilização do perfil do usuário, tentando recomendar itens que são similares aos que o usuário gostou no passado. O foco desses sistemas é aprender as preferências do usuário e filtrar dentre os novos itens, aqueles que mais se adequarem as preferências do usuário.

Em um sistema baseado no conteúdo, o usuário fornece, de forma implícita ou explícita, suas preferências e restrições, e o sistema cruza estas descrições com os itens contidos em um catálogo de itens.

Embora a filtragem baseada no conteúdo venha sendo usada com sucesso em vários domínios, essa técnica apresenta uma série de limitações:

- Os atributos geralmente precisam ser manualmente cadastrados para os itens, mesmo com a tecnologia atual, mídias como som e vídeo apresentam grande dificuldade de serem analisados automaticamente para extração automática de atributos. Muitas vezes não é possível definir os atributos manualmente devido a limitações de recursos.
- Nas técnicas de filtragem baseadas no conteúdo, apenas são encontrados os itens parecidos com os já conhecidos pelo usuário, não é possível recomendar itens ao usuário se ele ainda não avaliou outros itens com conteúdos similares.
- Os métodos baseados no conteúdo não são capazes de avaliar as descrições do item quanto a dimensões subjetivas, como qualidade. Por exemplo, em um sistema que faz recomendações de notícias de um jornal, é muito difícil diferenciar um texto mal escrito de um bem escrito, se possuírem conteúdos muito semelhantes.

## 2.5.2 Filtragem Colaborativa

A abordagem da Filtragem Colaborativa foi proposta para atender pontos que estavam em aberto na Filtragem Baseada em Conteúdo (HERLOCKER, 2000; ANSARI, 2000). A Filtragem Colaborativa não necessita de conhecimento do conteúdo dos itens.

O primeiro sistema criado com esta abordagem foi o *Tapestry* (GOLDBERG, 1992) que permitia ao usuário especificar qual tipo de informação iria receber, por exemplo, fazendo uma consulta do tipo: “mostre-me todos os memorandos que uma determinada pessoa considera como importante”. A idéia neste tipo de abordagem é a de que membros de uma comunidade podem ser beneficiados pela experiência de outros, antes de decidir por ler uma dada informação.

A técnica de Filtragem Colaborativa baseia-se no fato de que as melhores recomendações para um indivíduo são aquelas fornecidas por pessoas que possuem gostos similares aos dele (vizinhos). A essência está na troca de experiências entre as pessoas que possuem interesses comuns. Estes tipos de sistemas tentam prever itens aos usuários de acordo com itens avaliados por outros usuários. Basicamente, o sistema utiliza informações da base de dados para encontrar os pares (pessoas com interesses similares) para assim gerar a recomendação de acordo com os pares.

O perfil de um usuário em um sistema colaborativo consiste tipicamente em um vetor de itens e suas avaliações, sendo constantemente incrementado durante as interações do usuário e o sistema no tempo (BURKE, 2002).

A Filtragem Colaborativa apresenta algumas vantagens, como por exemplo, a possibilidade de apresentar aos usuários recomendações automáticas. *GroupLens* (KONSTAN *et al.*, 1997), *Video Recommender* (HILL *et al.*, 1995) e *Ringo* (SHARDANAND e MAES, 1995) foram os primeiros que utilizaram as técnicas de Filtragem Colaborativa para gerar predições automáticas. Nessa técnica, o usuário pode receber recomendações de assuntos que não estão sendo pesquisados de forma ativa. Outra contribuição importante da Filtragem Colaborativa

refere-se à possibilidade de formação de grupos de usuários pela identificação de seus gostos e interesses similares.

No contexto de Filtragem Colaborativa existem duas técnicas de aplicação: baseadas no usuário (*user-based*) e baseada em modelo (*model-based*).

A primeira conhecida como ***user-based*** (SHARDANAND e MAES, 1995; KONSTAN *et al.*, 1997; BREESE *et al.*, 1998; RESNICK *et al.*, 1994; HERLOCKER *et al.*, 1999; SARWAR *et al.*, 2000) se fundamenta na idéia que uma pessoa pertence a um grupo de indivíduos com interesses similares e como resultado, itens avaliados pelos indivíduos podem ser utilizados como base para recomendar itens.

A segunda, conhecida como ***model-based*** (SHARDANAND e MAES, 1995; BREESE *et al.*, 1998; AGGARWAL *et al.*, 1999; KITTS *et al.*, 2000), analisa informações do histórico e perfil do usuário para identificar relações entre um item e outros itens da comunidade. Por exemplo, a compra de um item pode estar relacionada à compra de outro item (ou vários itens), e então essas relações lógicas são utilizadas para criar as regras para recomendação.

As diferenças da utilização das técnicas de aplicação são que na técnica *model-based*, por utilizar regras pré-definidas, produz as recomendações mais rapidamente, porém necessita de tempo para criação das regras e as recomendações têm menos qualidade em relação às do método *user-based*. Por outro lado, o modelo *user-based* produz melhores resultados, mas acaba sofrendo com problemas de escalabilidade, em que a complexidade do processamento aumenta proporcionalmente com cada novo usuário ou item na comunidade.

### 2.5.2.1 Técnicas aplicadas na Filtragem Colaborativa

A seguir, são descritas as principais técnicas usadas para Filtragem Colaborativa.

#### 2.5.2.1.1 Correlação linear

Shardanand e Maes (1995) e Resnick *et al.*, (2000) trabalharam diversas variações de uma técnica baseada na correlação estatística de *Pearson* considerando as avaliações dos usuários.

Desde então esta técnica foi muito utilizada e melhorada em várias pesquisas. A fórmula da correlação prediz que a avaliação dada por um usuário a um artefato diferirá da avaliação média desse usuário por uma combinação linear de todas as avaliações de todos os usuários para o artefato. Variações dessa abordagem aparecem em Shardanand e Maes (1995) que insere valores de ponto inicial para as correlações, de modo que somente os usuários cuja correlação excede o ponto inicial sejam considerados na combinação linear que prediz a avaliação para o usuário alvo.

As técnicas de correlação apresentam algumas desvantagens (HERLOCKER, 2004), a principal é: se dois usuários não avaliarem nenhum item em comum, o método de correlação não consegue calcular similaridade entre eles, mesmo se compartilharem de interesses comuns.

#### 2.5.2.1.2 Classificador *Bayesiano* e Redes *Bayesianas*

Breese *et al.* (1998) listaram e testaram diversos algoritmos para a recomendação colaborativa. Eles propuseram uma alternativa para encontrar dependências entre artigos usando um classificador *Bayesiano* e um modelo de rede *Bayesiana*. A idéia é similar ao da correlação linear. Porém dois problemas foram encontrados: (1) a necessidade de calcular as probabilidades condicionais de todas as avaliações possíveis para um artigo dado e todas as avaliações possíveis de outros artigos, o que é computacionalmente trabalhoso e (2) não conseguir estimar a qualidade da predição que está fazendo.

#### 2.5.2.1.3 Redes Neurais utilizando técnicas de redução de características

Billsus e Pazzani (*apud* HERLOCKER, 2000) apresentaram uma estrutura para aplicar os algoritmos da aprendizagem de máquina somados com as técnicas da redução, tais como *singular value decomposition* ou o ganho da informação. Eles usaram técnicas de redução da característica para diminuir a dimensão dos dados avaliados, e então, aplicam as redes neurais nos dados simplificados para construir um modelo de recomendação.

#### 2.5.2.1.4 Regras de associação

Uma grande variedade de estruturas da regra de associação e algoritmos foram publicados, incluindo *Apriori* (AGGARWAL *et al.*, 1994; HERLOCKER, 2000). Uma extensão das regras de associação é a chamada regra quantitativa de associação (AGGARWAL *et al.*, 1999), em que encontra associações entre atributos com valores categorizados. As regras quantitativas de associação têm o potencial de expandir as regras de associação aos domínios da classificação.

Alguns resultados que adaptam essas regras às tarefas da classificação são mostrados em Liu *et al.* (1998), que apresenta o algoritmo *CBA-RG* (baseado no *Apriori*) e uma boa estrutura para executar a classificação associativa. As regras de associação foram muito usadas na mineração de dados para a Internet, usadas para descobrir padrões de navegação e para facilitar a melhor organização e estrutura de páginas *Web* (MOBASHER *et al.*, 2000). Adomavicius *et al.* (2005) desenvolveram um Sistema de Recomendação de páginas *Web* usando o algoritmo de *Apriori* para minerar as regras de associação sobre o histórico de navegação dos usuários. Sarwar (2001) trabalhou um algoritmo de regra de associação para encontrar as melhores recomendações (*Top-N recommendation*), além disso, ele diminui a complexidade do processo pré-selecionando um número reduzido de usuários que são os mais próximos ao usuário-alvo.

### 2.5.3 Filtragem Híbrida

A abordagem da Filtragem Híbrida procura combinar Filtragem Colaborativa e Filtragem Baseada em Conteúdo visando criar um sistema que possa melhor atender às necessidades do usuário (HERLOCKER, 2000). Os sistemas *Fab* (BALABANOVIC, 1997), o *Recommenz* (GARDEN, 2005) e o *Rascal* (MCCAREY e CINNÉIDE, 2005), tiveram destaque em trabalhar com essa abordagem.

Essa abordagem é constituída de vantagens proporcionadas pela Filtragem Colaborativa e pela Filtragem Baseada em Conteúdo, unindo o melhor das duas técnicas e reduzindo as fraquezas de cada uma.



Existem diferentes maneiras de combinar a Filtragem Colaborativa e a Filtragem Baseada em Conteúdo, que podem ser classificadas da seguinte maneira:

1. Desenvolvendo os métodos separadamente e depois combinar as predições;
2. Incorporando algumas características do modelo baseado em conteúdo no modelo colaborativo;
3. Incorporando algumas características do modelo colaborativo no modelo baseado em conteúdo;
4. Construindo um modelo único que possua características das duas técnicas ao mesmo tempo.

#### **2.5.4 Técnicas aplicadas em pesquisas**

A seguir é apresentada a Tabela 2 de classificação das técnicas aplicadas a Sistemas de Recomendação proposta por Adomavicius e Tuzhilin (2005). Nesta tabela o autor cita uma série de pesquisas que fazem uso das técnicas apresentadas. Esta tabela procura ilustrar o número de pesquisas que têm sido realizadas na área de Sistemas de Recomendação, destacando a aplicação de técnicas variadas.

Deve-se observar que o autor apresenta duas grandes classes de técnicas aplicadas a Sistemas de Recomendação (ADOMAVICIUS e TUZHILIN, 2005): baseada em Heurística (baseado em memória) e baseada em Modelo. O autor define técnicas baseadas em Heurística como sendo heurísticas que fazem predições de avaliações baseando-se em toda a coleção de avaliações feitas pelos usuários aos itens, enquanto técnicas baseadas em Modelo utilizam a coleção de avaliações para aprender o modelo, o qual é utilizado para realizar predições de avaliações.

**Tabela 2: Classificação das técnicas utilizadas em Sistemas de Recomendação. Adaptado de Adomavicius e Tuzhilin (2005).**

Técnicas de Recomendação	Técnicas aplicadas	
	Baseada em Heurística	Baseada em Modelo
Baseada em Conteúdo	<p>Técnicas mais utilizadas:</p> <ul style="list-style-type: none"> <li>• TF-IDF (recuperação de informação)</li> <li>• Agrupamento</li> </ul> <p>Exemplos de Pesquisas:</p> <ul style="list-style-type: none"> <li>• Lang, 1995</li> <li>• Balabanovic e Shoham, 1997</li> <li>• Pazzani e Billsus, 1997</li> </ul>	<p>Técnicas mais utilizadas:</p> <ul style="list-style-type: none"> <li>• Classificadores Bayesianos</li> <li>• Agrupamento</li> <li>• Árvores de Decisão</li> <li>• Redes Neurais</li> </ul> <p>Exemplos de Pesquisas:</p> <ul style="list-style-type: none"> <li>• Pazzani e Billsus, 1997</li> <li>• Billsus e Pazzani, 2000</li> <li>• Zhang et al., 2002</li> </ul>
Colaborativa	<p>Técnicas mais utilizadas:</p> <ul style="list-style-type: none"> <li>• Correlação (<i>coseno, Pearson, Spearman</i>)</li> <li>• Teoria dos Gráficos</li> </ul> <p>Exemplos de Pesquisas:</p> <ul style="list-style-type: none"> <li>• Resnick et al., 1994</li> <li>• Hill et al., 1995</li> <li>• Shardanand e Maes, 1995</li> <li>• Breese et al., 1998</li> <li>• Nakamura e Abe, 1998</li> <li>• Aggarwal et al., 1999</li> <li>• Delgado e Ishii, 1999</li> <li>• Pennock e Horwitz, 1999</li> <li>• Sarwar et al., 2001</li> <li>• Massa et al. 2004</li> </ul>	<p>Técnicas mais utilizadas:</p> <ul style="list-style-type: none"> <li>• Redes Bayesianas</li> <li>• Agrupamento</li> <li>• Redes Neurais</li> <li>• Regressão Linear</li> <li>• Modelos Probabilísticos</li> </ul> <p>Exemplos de Pesquisas:</p> <ul style="list-style-type: none"> <li>• Billsus e Pazzani, 1998</li> <li>• Breese et al., 1998</li> <li>• Ungar e Foster, 1998</li> <li>• Chien e George, 1999</li> <li>• Getoor e Sahami, 1999</li> <li>• Pennock e Horwitz, 1999</li> <li>• Goldberg et al., 2001</li> <li>• Kumar et al., 2001</li> <li>• Pavlov &amp; Pennock, 2002</li> <li>• Shani et al., 2002</li> <li>• Yu et al., 2004</li> <li>• Hofmann, 2004</li> <li>• Marlin, 2003</li> <li>• Si e Jin, 2003</li> </ul>

Híbrida	Combinando componentes baseados em conteúdo e colaborativos: <ul style="list-style-type: none"> <li>• Combinação linear de avaliações</li> <li>• Esquemas variados de votação</li> <li>• Incorporando um componente como parte da heurística de outro</li> </ul> Exemplos de Pesquisas: <ul style="list-style-type: none"> <li>• Balabanovic e Shoham, 1997</li> <li>• Claypool et al., 1999</li> <li>• Good et al., 1999</li> <li>• Pazzani, 1999</li> <li>• Billsus e Pazzani, 2000</li> <li>• Tran e Cohen, 2000</li> <li>• Melville et al., 2002</li> </ul>	Combinando componentes baseados em conteúdo e colaborativos: <ul style="list-style-type: none"> <li>• Incorporando um componente como parte de um modelo em outro</li> <li>• Construindo um modelo unificado</li> </ul> Exemplos de Pesquisas: <ul style="list-style-type: none"> <li>• Basu et al., 1998</li> <li>• Condliff et al., 1999</li> <li>• Soboroff e Nicholas, 1999</li> <li>• Ansari et al., 2000</li> <li>• Popescul et al., 2001</li> <li>• Schein et al., 2002</li> <li>• Cazella e Alvares, 2004</li> </ul>
---------	---	--

A seguir são apresentados os problemas relativos aos Sistemas de Recomendação, especialmente na técnica de Filtragem Colaborativa.

## 2.6 Problemas em Sistemas de Recomendação

Na medida da evolução da Filtragem Colaborativa, cinco limitações nas recomendações foram expostos (DIEBERGER *et al.*, 2000; SARWAR, 2000; HERLOCKER, 2004; MASSA, 2004), e estes problemas são apresentados a seguir.

### 2.6.1 Problema do novo usuário

Na Filtragem Colaborativa, novos usuários não podem receber recomendações por não possuírem um histórico de avaliações feitas sobre itens, e com isso, não é possível correlacioná-los a outros usuários. Esse grupo de usuários merece uma atenção especial, necessitando de recomendações com qualidade como forma de incentivo para continuar utilizando a comunidade. Cazella e Alvares (2004) buscaram solucionar esse problema, utilizando CV Lattes<sup>2</sup> como ponto

<sup>2</sup> CV Lattes, <http://www.lattes.cnpq.br>

de partida para criação do perfil do usuário, porém o objetivo deles é a geração automática de comunidades dentro do ambiente, não focando a recomendação de itens.

### 2.6.2 Problema do primeiro avaliador

Novos itens são adicionados diariamente em uma comunidade virtual. Como a Filtragem Colaborativa faz as predições de acordo com as avaliações sobre os itens, é necessário que um grande número de pessoas tenha qualificado um item, para que este possa ser recomendado a algum usuário.

### 2.6.3 Matrizes esparsas

É comum que uma comunidade virtual cresça e tenha muitos usuários e muitos itens. Na prática, um usuário avalia somente uma pequena parte dos itens existentes, resultando uma matriz esparsa. Este problema também está relacionado ao fato da Filtragem Colaborativa necessitar um número significativo de avaliações de usuários sobre itens antes de começar a gerar recomendações. Para medir a esparsividade da matriz é calculada a relação de células vazias pelo total possível de dados. Em geral, nas bases de dados de comunidades esse problema em geral é comum, *MovieLens* é 95,85% esparsa (HERLOCKER, 2000) e *Epinions* é 99,99% esparsa (MASSA e AVESANI, 2004).

A consequência da matriz esparsa na recomendação é uma correlação baixa quando tenta comparar dois usuários com poucos itens avaliados em comum, por essa razão, a Filtragem Colaborativa fica prejudicada. É comum também, existir usuários sem nenhum item avaliado em comum com outros usuários e com isso, a similaridade não pode ser calculada entre eles. Uma proposta para resolução desse problema foi a técnica *Singular Value Decomposition* (SARWAR *et al.*, 2000), que reduz a dimensão da matriz e avalia em pequenas partes, reduzindo a esparsividade.

Porém, sua utilização em matrizes muito esparsas, não obteve resultados satisfatórios (SARWAR *et al.*, 2000).

#### **2.6.4 Super-especialização do usuário**

Outra limitação bastante citada na literatura refere-se ao fato da Filtragem Colaborativa gerar recomendações baseando-se somente no perfil do usuário. Desta forma, os usuários não recebem recomendações de áreas que não são similares às áreas incluídas em seu perfil, com isso, o sistema não recomenda itens fora do domínio de atuação do usuário.

Esta situação pode criar um descontentamento no usuário, uma vez que os interesses dos usuários tendem a se modificar e se aperfeiçoar com o tempo (BALABANOVIC e SHOHAM, 1997). Este problema torna-se mais perceptível em Sistemas de Recomendação baseado em conteúdo, onde a recomendação de itens é baseada na similaridade de conteúdos entre itens de interesse do usuário.

#### **2.6.5 Problema do tipo de arquivo**

Outro desafio é a dificuldade de se obter boas recomendações, com o mesmo algoritmo, para diferentes formatos de arquivos, como é o caso de comunidades virtuais, que possuem arquivos tais como: textos, imagens, filmes, sons, etc.

Em geral utilizando-se a Filtragem Colaborativa esse problema não se torna evidente, já que a recomendação é feita através de avaliações feitas pelos usuários e não por modelos que utilizem o conteúdo do artefato.

### **2.7 Privacidade do usuário**

Para gerar recomendação, é necessário que o sistema armazene as ações do usuário (no histórico de leitura de textos ou suas avaliações), e muitas vezes o usuário não sabe ou não deseja

que sejam armazenadas. O sistema deve ser capaz de entender e guardar as informações do usuário, mas também de administrar a sensibilidade em relação à privacidade do usuário. Uma das formas é ter certeza de que os usuários do sistema sabem quais informações estão sendo armazenadas e como serão manipuladas. Isso é chamado por Erickson e Kellogg (2000) de "*social translucence*", que é a soma de visibilidade, consciência e contabilidade.

## 2.8 Considerações finais

Nesse capítulo foi apresentada a descrição de Sistemas de Recomendação, a revisão de literatura com as pesquisas que marcaram a evolução da filtragem de informação para o Sistema de Recomendação. Também foram apresentadas as principais técnicas para a aplicação do Sistema de Recomendação bem como as principais limitações da Filtragem Colaborativa.

A abordagem utilizada nessa pesquisa é a Filtragem Colaborativa, que recomenda itens baseado no perfil gerado pelas ações do usuário na comunidade (RESNICK *et al.*, 1994; KONSTAN *et al.*, 1997). A maior vantagem da Filtragem Colaborativa é não depender do conteúdo dos itens, podendo automatizar o processo de recomendação baseado somente nas opiniões dos usuários.

A idéia de gerar recomendações automáticas é muito importante, já que independe de um especialista para criar regras e inserir no sistema. Porém, com o progresso nos estudos de Filtragem Colaborativa, foram identificados problemas que limitam a realização das recomendações (SARWAR *et al.*, 2000).

No próximo capítulo é apresentado o conceito de Redes de Confiança, bem como a definição de confiança, suas propriedades e pesquisas relacionando a Rede de Confiança com Sistema de Recomendação.

## Capítulo 3

# Redes de Confiança

---

“Aquele que não tem confiança nos outros, não lhes pode ganhar confiança.”

*Lao Tsé*

Nesse capítulo é definido como é tratada a confiança e como pode ser aplicada em Sistemas de Recomendação. São apresentadas as propriedades da confiança bem como os modelos de propagação possíveis.

### 3.1 Definindo confiança

A confiança é fundamental para a vida social. Existem várias definições para confiança, as mais comuns tratam a confiança como um valor cognitivo positivo no julgamento de outras pessoas (COOK e COOPER, 2003), ou um tipo de expectativa sobre os comportamentos de outras pessoas (HARDIN, 2001). Em termos gerais, a confiança é crença nas boas intenções de outras pessoas (YAMAGISHI, 1998). Confiança reforça cooperação, agindo como um “lubrificante” psicológico para o bom desenrolar de processos sociais. Em uma palavra, a confiança é uma condição *sine qua non* de convivência em grupo (ROTTER, 1971).

Definir confiança com um sentido único, em muitos casos, pode ser impossível. Para (ROBINSON e JACKSON, 2001), a confiança relaciona-se com a fé nas pessoas, que está ligada ao fato de que alguém manterá sua palavra. Mas no artigo de Deutsch (1962), a definição de confiança compreende tanto a noção de "relevância motivacional" como a de "previsibilidade". Esse conceito de confiança envolve expectativas de eventos que ocorrerão no futuro e a possibilidade de sofrer algum tipo de perda se a confiança não for correspondida. Para Deutsch (1962), a definição de um indivíduo com confiança em um determinado evento é:

"se ele espera sua ocorrência e sua expectativa condiz a um comportamento que ele percebe ter conseqüências motivacionais maiores se a expectativa não for confirmada do que conseqüências motivacionais positivas se for confirmada" (DEUTSCH, 1962, p.266).

Essa definição de confiança contém também a distinção entre confiar e apostar, quando a chance da ocorrência de certo evento é pouco provável e ainda assim estamos dispostos a correr o risco. Gautschi (2000) também enfatiza o elemento de incerteza envolvido na confiança:

“‘Confiar em alguém’ implica a possibilidade de ficar desapontado. Uma vez depositada a confiança, ela pode ser tanto honrada como violada pelo depositário. [...] Uma vez que assumimos que a confiança é uma decisão binária (isto é, a confiança é depositada ou retirada), ‘ser cauteloso’ significa, portanto, que consideramos pequena a perda provável devida à confiança mal depositada [...]. Porém, assumir o risco de confiar pode valer a pena, pois é a única maneira de obter informação sobre os incentivos do depositário. Ademais, depositar e posteriormente



honrar a confiança garante um retorno a ambos os atores que é maior do que seus retornos quando se retira a confiança.” (GAUTSCHI, 2000, p.131)

Essa noção de confiança assinala também o que pode influenciar o comportamento de um indivíduo: a probabilidade de ocorrer um evento negativo e a informação eventual sobre a contraparte. Porém, em situações com  $n$  participantes, não parece factível obter informações sobre todo mundo. De acordo com Bacharach e Gambetta (2000), há sinais que os indivíduos usam para interpretar a confiabilidade dos outros. Mas outro modo de transferir confiança de um grupo de pessoas conhecidas para um nível generalizado de pessoas é sugerido por Coleman (1990), em que mediadores podem facilitar a transferência. Por exemplo: *A* conhece *B*, mas não conhece *C*, que é conhecido de *B*; *A* pode então confiar em *C* por meio da relação que *A* tem com *B*. Se *C* não corresponder à confiança de *A*, *A* pode então retaliar *C*. Porém, nesse contexto racional é difícil ver como se pode confiar nas pessoas "em geral"; pois a confiança está relacionada com a informação e o contexto em cada situação específica.

De acordo com Luhmann (1979), a confiança é importante porque reduz a complexidade da sociedade e possibilita que a vida social decorra com mais suavidade. Yamagishi (1998) também defende a necessidade da confiança para haver prosperidade e superar os desequilíbrios em diferentes contextos.

O trabalho de Marsh (1994) formaliza confiança no sentido computacional, levando em consideração seus aspectos sociais e tecnológicos. Mais especificamente, o trabalho de Abdul-Rahman e Hailes (1997) separa a confiança em duas categorias: a) confiança em um contexto específico interpessoal, a qual estamos mais interessados, é uma situação onde um usuário confia em outro usuário com respeito a uma situação específica, mas não necessariamente a outra e b) sistema/confiança impessoal que descreve que os usuários confiam nas informações presentes no sistema, seja como forma de avaliações, revisões, recomendações, etc.

Conforme, Diego Gambetta:

“a confiança (ou, simetricamente, desconfiança) é um nível particular de probabilidade subjetiva com que um agente executará uma ação, ambos antes que nós possamos monitorar tal ação (ou independente da capacidade de nunca podermos monitorar) e em um contexto que reflita a nossa própria ação.”

Pode-se destacar três pontos importantes na definição acima:

- 1) A confiança é subjetiva;
- 2) A confiança é afetada por ações que nós não podemos monitorar;
- 3) O nível de confiança depende de como nossas próprias ações são afetadas pelas ações do agente.

A confiança nem sempre é totalmente racional, mas do ponto de vista analítico, a definição de Levi (1998) parece apropriada ao dizer que a confiança é "racional e relacional", relacional no sentido que depende de quem se quer confiar.

Enfim, a confiança é uma variável usada de modo tão amplo que também ganhou uma grande variedade de definições. Seus aspectos fundamentais são:

- Contém risco,
- Gera informação,
- Possui expectativas em relação ao comportamento da contraparte,
- Possibilidade de obter confiança dos outros,
- Possibilidade de obter um retorno maior se confiar.

## 3.2 Rede de Confiança

Uma Rede de Confiança de uma comunidade, também chamada rede social, é construída através da união de todas as declarações de confiança dos usuários desta comunidade, que pode ser representada na forma de um único grafo, onde os nós são os usuários e as arestas

são as declarações de confiança estabelecido de um usuário para outro. A Figura 5 mostra um exemplo de uma Rede de Confiança.




Figura 5: Exemplo de uma Rede de Confiança.

As declarações de confiança são valores que indicam desde a total confiança até a total desconfiança. A Figura 6 mostra uma Rede de Confiança com as declarações de confiança da comunidade.




Figura 6. Rede de Confiança. Os nós representam os usuários e as arestas os valores de confiança na direção da seta. A linha pontilhada representa um valor que pode ser predito pelo sistema.

### 3.2.1 Confiança explícita

É a opinião expressa por um usuário *A* sobre um usuário *B* a respeito de uma habilidade percebida ou de uma determinada característica deste usuário *B*. Ela pode ser feita de diversas formas, utilizando: escalas, ordenamento, classificação, notas, textos, etc. Independente da forma utilizada é importante que o sistema disponibilize um padrão para que se possam estabelecer as conexões entre os usuários da comunidade.

Existem muitas possibilidades de classificação de quanto uma pessoa confia em outra, O sistema *Advogato* (LEVIN, 1998) utiliza três níveis (aprendiz, especialista, mestre) para a

classificação dos seus membros. O *Orkut*<sup>3</sup> oferece aos usuários a capacidade de avaliar algumas características dos seus amigos, incluindo a sua confiabilidade, em nível de zero a três “carinhas sorridentes”. Projetos de *Web* semântica utilizam uma escala discreta [1,9], [1,10] (GOLBECK *et al.*, 2003), ou um valor real do intervalo [0,1] (RICHARDSON *et al.*, 2003).

### 3.2.2 Desconfiança

A desconfiança é um dos temas mais controversos em redes sociais, sobretudo quando se considera métricas de confiança e propagação de confiança. A maioria das abordagens ignora completamente a desconfiança e só consideram plena confiança ou graus de confiança (RICHARDSON *et al.*, 2003). Outros, (ABDUL-RAHMAN e HAILES, 1997; GOLBECK *et al.*, 2003), permitem avaliações de desconfiança, porém, não consideram as sutis diferenças relativas às noções distintas de confiança e de desconfiança.

De acordo com Gans *et al.* (2001), “desconfiança é considerado apenas o outro lado da moeda, ou seja, há geralmente uma escala simétrica com total confiança em um lado e absoluta desconfiança no outro lado”. Além disso, alguns pesquisadores consideram a noção de desconfiança como a falta de confiança nas informações que possui da pessoa. Marsh (1994) assinalou que esses dois conceitos, a falta de confiança e a desconfiança, podem não estar em lados opostos. Por exemplo, na ausência de pessoas confiantes, a pessoa pode ser mais propensa a aceitar recomendações de pessoas que não indicou grau de confiança, provavelmente devido da falta de experiência prévia nessas pessoas que desconfia explicitamente, resultante de experiências ruins no passado (MARSH, 1994).

Gans *et al.* (2001) foi um dos primeiros trabalhos a reconhecer a importância da desconfiança, definindo a desconfiança como: “um fenômeno irreduzível que não pode ser

---

<sup>3</sup> Orkut – Rede social com o objetivo de ajudar seus membros a criar novas amizades e manter relacionamentos. Disponível em [www.orkut.com](http://www.orkut.com).

deduzido por quaisquer mecanismos sociais". Em seu trabalho, Gans *et al.* (2001), explicita a distinção entre confiança, desconfiança e desconfiança. Além disso, os autores indicam que a desconfiança poderia ser altamente relevante para as redes sociais. O seu impacto não é necessariamente negativo, mas que também pode influenciar em uma Rede de Confiança de uma forma extremamente positiva.

Guha *et al.* (2004) reconhece o papel de desconfiança no que diz respeito às aplicações da propagação de confiança, argumentando que "as declarações de desconfiança são muito úteis para auxiliar os usuários a ajustar sua Rede de Confiança". Por exemplo, suponha que um *A* confia cegamente em *B*, que confia cegamente em *C*, que confia cegamente em *D*. No entanto, *A* pode explicitar que não confia em *D*. Esta última afirmação de desconfiança, conseqüentemente, garante que *A* não vai aceitar as crenças e avaliações de *D*, independentemente de *A* confiar em *B*, *B* confiar em *C* e *C* confiar em *D*.

Nesta dissertação tratamos a desconfiança como o nível zero em uma escala de números inteiros de [0,3]. No momento que uma pessoa indica não confiar em outra pessoa, todas as avaliações que foram preditas iguais à pessoa que desconfia são eliminadas da lista final de recomendações, ajustando as recomendações.

### 3.2.3 Propriedades da confiança

Uma Rede de Confiança possui algumas propriedades importantes e bem definidas, são elas: subjetiva, assimétrica, transitiva e contextualizada. Em seguida cada uma delas é detalhada.

#### 3.2.3.1 Subjetiva

Confiança é uma opinião pessoal. Muitas vezes, duas pessoas têm opiniões muito diferentes sobre a mesma pessoa, por isso, é normal um usuário possuir diferentes valores de

confiança dependendo de quem o classifica. Na Figura 7, pode-se ver que *A* é confiável para *B* em  $0,4$  e para *C* em  $0,8$ .




Figura 7: Exemplo de Rede de Confiança subjetiva.

### 3.2.3.2 Assimétrica

O envolvimento de duas pessoas em uma relação de confiança não é necessariamente idêntico em ambos os sentidos. Uma vez que os indivíduos têm diferentes experiências e preferências, é compreensível que duas pessoas confiem uma na outra em níveis diferentes. Como pode-se ver na Figura 8 o usuário *A* confia em *B* em  $0,4$  e *B* confia em *A* em  $0,7$ .




Figura 8: Exemplo de Rede de Confiança assimétrica.

### 3.2.3.3 Contextualizada

A confiança entre usuários em uma comunidade depende diretamente do contexto em que o usuário está inserido. Só é possível estabelecer uma relação de confiança com uma pessoa após uma interação com ela, positiva ou negativa, em um determinado contexto. Quando dizemos que confiamos em alguém, sabemos determinar exatamente em que contexto estamos nos referindo. Por exemplo, um mecânico de carro pode ser confiável em uma oficina mecânica, mas nada se pode afirmar do mesmo profissional em outro contexto, realizando outro serviço.




Figura 9: Rede de Confiança contextualizada, cada aresta indica um grau de confiança para cada contexto específico.

### 3.2.3.4 Transitiva

Quando pedimos a um amigo confiável uma opinião sobre uma pessoa, estamos tendo a opinião de um amigo para nos ajudar a formar nosso pensamento preliminar sobre a outra pessoa. Porém, confiança pode não ser perfeitamente transitiva, no sentido matemático, isto é, se  $A$  confia muito em  $B$ , e  $B$  confia muito em  $C$ , nem sempre se pode inferir que  $A$  confia muito em  $C$ . No entanto, existe a possibilidade da confiança ser inferida a partir de outras pessoas.

Na Figura 10 pode-se ver a aresta pontilhada entre  $A$  e  $C$ , onde não houve uma declaração explícita de confiança entre eles. Para esse caso, pode-se inferir um nível de confiança através de métricas de confiança, seguindo a idéia: se  $A$  confia em  $B$  e  $B$  confia em  $C$ , então é possível inferir o quanto  $A$  confia em  $C$ .

Computacionalmente, esta idéia de propagação da confiança por conexões de pessoas tem sido amplamente estudada e implementada (GRAY *et al.*, 2002; GUHA *et al.*, 2004; JOSANG 1996; JOSANG *et al.*, 2006; RICHARDSON *et al.*, 2003; ZIEGLER e LAUSEN, 2004).




Figura 10: Transitividade direta em uma Rede de Confiança, a aresta tracejada indica um valor que pode ser inferido a partir da relação de  $A$  com  $B$  e  $B$  com  $C$ .

Na seção seguinte são abordadas as métricas de confiança que tem por objetivo encontrar essas relações de transitividade.

### 3.2.4 Métricas de confiança

Métrica de confiança é a técnica utilizada para inferir um nível de confiança entre os usuários de uma comunidade (GOLBECK *et al.*, 2003; LEVIEN, 2001; ZIEGLER e LAUSEN, 2004; MASSA e AVESANI, 2004).

As métricas podem ser classificadas em global e local (MASSA e AVESANI, 2004; ZIEGLER e LAUSEN, 2004). *Confiança local* leva em conta as opiniões subjetivas dos usuários para predizer o quanto confia em indivíduos desconhecidos por ele. Por esta razão, o grau de confiança local de um determinado usuário é diretamente dependente de quais ou quantos indivíduos foram utilizados para predizer o grau de confiança.

Por outro lado, a *confiança global* calcula uma pontuação de confiança a partir de como a comunidade confia em um usuário ou artefato. *PageRank* (PAGE *et al.*, 1998), um dos algoritmos do *Google.com*, é um exemplo de métrica global. Em seu processamento ele calcula um valor para uma página Web que é o mesmo para todos os usuários do sistema, independentemente das suas preferências.

As métricas de confiança local são mais precisas e adaptadas ao usuário, porém elas têm um custo computacional elevado, uma vez que elas devem ser calculadas para cada usuário, enquanto na métrica global é computada apenas uma vez para toda a comunidade. Outra característica interessante da confiança local é o fato de serem resistentes a ataques (LEVIEN, 2001): os usuários considerados maliciosos são excluídos da propagação de confiança e não influenciam na personalização de usuários que não confiam neles explicitamente. Gori e Witten (2005) mostram que a exploração de pessoas maliciosas é um problema inerente e inevitável para a métrica de confiança global. As diferenças entre métricas de confiança local e global ficam ainda mais evidentes no tratamento de usuários controversos (MASSA e AVESANI, 2005).

Há muitas formas de propagar a confiança entre usuários (GUHA *et al.*, 2004; RICHARDSON *et al.*, 2003, ABDUL-RAHMAN e HAILES, 2000). Com base nesses trabalhos



Malinowski (2006) definiu três modelos distintos para propagação de confiança, são elas: propagação direta, propagação colaborativa e propagação baseada na similaridade.

### 3.2.4.1 Propagação direta

Esse modelo de propagação de confiança utiliza a confiança explícita do usuário para calcular as relações de confiança entre os membros da comunidade.

Guha *et al.* (2004) apresenta essa forma de propagação, assumindo que se um usuário  $A$  confia em  $B$  com um valor  $c_{AB}$  e  $B$  confia em  $D$  com valor  $c_{BD}$ , pela propagação direta é possível inferir que  $A$  confia em  $D$  em algum nível (RICHARDSON *et al.*, 2003; YU e SINGH, 2000). O modo mais utilizado para calcular a propagação direta é a multiplicação (GUHA *et al.*, 2004; KAMWAR *et al.*, 2003; RICHARDSON *et al.*, 2003), seguindo a idéia que a confiança de  $A$  para  $D$  é a multiplicação das confianças de  $A$  para  $B$  e de  $B$  para  $D$ .




Figura 11: Exemplos de propagação de confiança direta. As arestas pontilhadas representam os valores de confiança que podem ser preditos.

Golbeck (2005) desenvolveu um algoritmo mais detalhado para calcular o fator de confiança pela propagação direta. No trabalho, ele descreve o *TrustMail* como uma aplicação de avaliação de e-mails. O nível de confiança nesse sistema é calculado por inferência e propagação, na forma: se  $A$  confia em  $B$  e  $B$  confia em  $C$  então  $A$  confia em  $C$  em algum nível. A aplicação *TrustMail* avalia o remetente do *e-mail* em relação a sua reputação na Rede de Confiança e, com isso, cria uma avaliação para cada *e-mail* enviado. Estas avaliações dizem ao usuário se o e-mail é importante ou não. Valores de confiança no sistema são definidos em contextos específicos e também por um nível geral.

### 3.2.4.2 Confiança baseada na similaridade

A confiança baseada na similaridade objetiva definir valores baseados nas similaridades de preferências entre indivíduos. A idéia é encontrar a correlação entre usuários e estabelecer a confiança entre eles (ABDUL-RAHMAN e HAILES, 2000; MONTANER *et al.*, 2002). Jones e George (1998) notaram que as pessoas tendem a confiar mais em outras pessoas se eles compartilharem dos mesmos interesses. Ziegler e Lausen (2004) concluem, com base em uma comunidade de leitura de livros on-line, que dois usuários são mais semelhantes, quanto maior for a sua confiança estabelecida.

Em filtragem de informação, semelhanças entre os usuários normalmente são calculadas utilizando correlação de *Pearson*, vetor *coseno* ou correlação de *Spearman* (BREESE *et al.*, 1998; HERLOCKER *et al.*, 1999).




Figura 12: Exemplo de confiança pela similaridade.

### 3.2.4.3 Confiança Agregada

Como podem existir vários caminhos para encontrar a confiança entre indivíduos, Richardson *et al.* (2003) distingue três tipos diferentes de agregação dos caminhos: valor máximo, valor mínimo e médio. A abordagem de valor máximo utiliza somente o caminho com a máxima confiança, desprezando todos os outros caminhos, conforme Figura 13. A abordagem de valor mínimo, por sua vez, é mais pessimista, uma vez que só utiliza as pessoas com confiança de menor valor, conforme Figura 14. A abordagem média calcula a média dos valores de confiança de todos os caminhos disponíveis (GUHA *et al.*, 2004; KAMVAR *et al.*, 2003).




Figura 13: Confiança agregada pelo caminho de valor máximo.




Figura 14: Confiança agregada pelo caminho de valor mínimo.

### 3.3 Confiança em Sistemas de Recomendação

A introdução da confiança, em Sistemas de Recomendação, vem ganhando uma crescente atenção no meio acadêmico e naturalmente há muitas maneiras diferentes de medir e usar a confiança. Algumas pesquisas atuais têm utilizado a confiança para recomendar itens utilizando relacionamentos explícitos de confiança.

Por exemplo, o trabalho de Massa e Avesani (2004) constrói um modelo da confiança diretamente dos dados da confiança fornecidos por usuários como parte do serviço popular de *Epinions.com*. *Epinions.com* é um *site* que permite aos usuários revisar vários itens (carros, livros, música, etc.). Além disso, os usuários podem atribuir uma confiança aos revisores pelo nível que acharam útil a revisão. Massa e Avesani (2004) discutem que estes dados da confiança podem ser extraídos e usados como parte do processo da recomendação, especialmente como meios de reduzir o problema da esparsividade que impede várias técnicas tradicionais da filtragem colaboradora.

Nesse trabalho, ele verifica que é possível comparar usuários de acordo com seu grau de conexão no gráfico de confiança criado pelo *Epinions.com*. A idéia básica é medir a distância entre dois usuários, levando em consideração o número de arestas que conectam os usuários no grafo de confiança do *Epinions.com*. Apresenta ainda, que é possível comparar mais usuários com este método do que nas formas convencionais de similaridade por avaliações. Isso se deve, pelo fato das comparações baseadas na confiança facilitarem a identificação de grupos mais precisos e de

usuários vizinhos. Entretanto, apesar da pesquisa apresentar dados que demonstrem que com a confiança é possível recomendar a mais usuários do sistema, não foi mostrado se o método utilizado conserva a qualidade na recomendação.

Em um trabalho similar nos dados de *Epinions.com*, Massa e Bhattacharjee (2004) introduzem uma arquitetura confiança-consciente de recomendação que também utiliza a Rede de Confiança para definir um valor de quanto um usuário confia em todos os outros do sistema. Este sistema é bem sucedido em reduzir o erro médio de exatidão da predição para usuários que acabaram de entrar na comunidade (problema do novo usuário). Os dados da confiança são usados para aumentar a sobreposição entre perfis de usuário no sistema, e conseqüentemente o número de usuários comparáveis. Entretanto, nesse trabalho, falta uma comparação real entre uma técnica convencional de Filtragem Colaborativa e a técnica baseada em confiança.

Em outra pesquisa, Golbeck (2006) apresenta o *FilmTrust*, um Sistema de Recomendação de filmes baseado em redes sociais para gerar recomendações, nesse artigo ele apresenta o algoritmo *TidalTrust*, um algoritmo de inferência, que é utilizado como base para gerar as recomendações dos filmes.

Para computar o filme recomendado, a primeira etapa do sistema *FilmTrust* pesquisa os avaliadores que o usuário confiou diretamente. Se não houver ligações diretas do usuário para alguém que tenha feito avaliações, o sistema passa para o segundo nível e tenta encontrar ligações do usuário para avaliadores. Este processo repete até um caminho ser encontrado. Então, utilizando *TidalTrust*, a valor da confiança é calculado para cada avaliador a determinada profundidade. Depois que cada avaliador tenha seu valor de confiança inferido, os avaliadores com maior nível de confiança inferido são selecionados. Por fim, quando os avaliadores foram selecionados, as suas recomendações de filme (em número de estrelas) são calculadas.

### **3.4 Considerações finais**

Nesse capítulo foram apresentados os conceitos de Redes de Confiança, confiança e desconfiança, suas propriedades e as maneiras possíveis de se propagar a confiança. Além disso, foi apresentada como vem sendo utilizada a Rede de Confiança nos Sistemas de Recomendação.

No próximo capítulo é apresentado um modelo de Sistemas de Recomendação de itens somada a Rede de Confiança do usuário, com base nos trabalhos relacionados descritos.

## Capítulo 4

# Proposta de Solução: Recomendação Baseada na Rede de Confiança do Usuário

---

“Todas as coisas devem ser feitas da forma mais simples possível, porém não mais simples que o possível.”

*Albert Einstein*

Nesse capítulo, é apresentado o modelo de recomendação baseado na Rede de Confiança do usuário. O modelo se sustenta na idéia de que a opinião de uma pessoa confiável é relevante na recomendação de novos itens ao usuário. Além disso, é definido o domínio de aplicação para o modelo e detalhado um exemplo de como pode ser aplicado em um Sistema de Recomendação.

## 4.1 Descrição da proposta

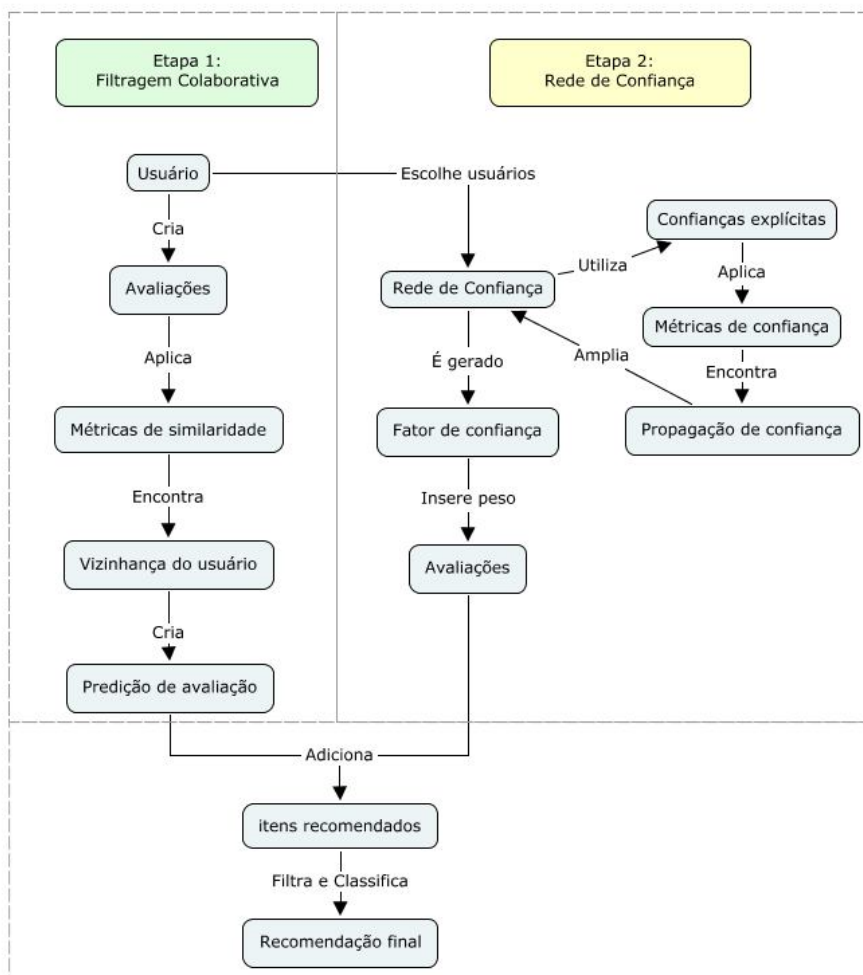
O modelo de recomendação por redes de confiança é baseado na idéia de que dentro de uma comunidade, as pessoas confiam umas nas outras, em níveis e contextos diferentes. Nesse sentido, considera-se que a Rede de Confiança do usuário pode melhorar a qualidade das recomendações geradas ao usuário. Além disso, pode servir como fator para classificação das recomendações, estabelecendo uma lista de interesses prioritários do usuário.

Outro fator importante do modelo é facilitar a integração de novos usuários na comunidade, tratando deste modo o problema do novo usuário, descrito na Seção 2.6.1, uma limitação da Filtragem Colaborativa. Esse problema prejudica principalmente o usuário que possui um histórico com pouca informação de suas preferências, seja na forma de avaliações sobre itens ou navegação do ambiente. Utilizando a Rede de Confiança, é possível gerar recomendações para o usuário a partir de apenas uma indicação de confiança do usuário, pois, com essa confiança direta pode-se propagar a confiança para outras pessoas que pertencem à Rede de Confiança da confiança direta.

Com base nesses aspectos, foi idealizado um modelo de recomendação que se baseia na Rede de Confiança para gerar recomendações ao usuário, representado na Figura 15.

## 4.2 Descrição do modelo

A Figura 15 representa o mapa conceitual do modelo proposto.



**Figura 15: Mapa conceitual do modelo, Filtragem Colaborativa somada à Rede de Confiança do usuário para gerar recomendações.**

Para entender melhor, o modelo foi dividido em duas etapas: Etapa 1: Filtragem Colaborativa e

Os valores em branco na tabela indicam valores que não puderam ser preditos, por falta de dados suficientes entre os usuários, ou por serem pontos de corte, eliminados após passar por filtros de acordo com a necessidade do sistema.



A seguir será apresentado a Etapa 2 do modelo que trabalha com a Rede de Confiança para gerar recomendações.

Etapa 2: Rede de Confiança, detalhados a seguir.

### 4.2.1 Etapa 1: Filtragem Colaborativa

Na Filtragem Colaborativa é utilizado o histórico do usuário, dentro da comunidade, para gerar as recomendações. Nessa etapa do modelo são utilizadas as avaliações sobre itens feitas pelo usuário para encontrar os seus vizinhos, através de métricas de similaridade (pessoas que compartilham dos mesmos interesses) e, com isso, criar uma predição de avaliação sobre itens que ele ainda não avaliou. A partir disso são recomendados itens a ele, classificados pelo maior valor de predição.

Resumindo, na técnica de Filtragem Colaborativa, três passos são importantes:

- i. *Correlacionar usuários*: Correlacionar o usuário com todos da comunidade e encontrar a similaridade entre ele e cada usuário;
- ii. *Filtrar vizinhos*: Filtrar os usuários com maior semelhança de interesses (vizinhos);
- iii. *Prever avaliações*: Inserir o peso de similaridade nas avaliações e computar as predições.

A seguir são detalhados os passos da Filtragem Colaborativa.

#### 4.2.1.1 Correlacionar usuários

Várias técnicas foram desenvolvidas com esse propósito, no Capítulo 2 estão apresentadas algumas delas, tais como: Correlação de *Pearson*, Correlação de *Spearman* e Correlação *Cosseno* (BREESE *et al.*, 1998; HERLOCKER *et al.*, 1999).

A técnica mais utilizada na Filtragem Colaborativa é a correlação de *Pearson*, onde a similaridade entre dois usuários é calculada a partir das avaliações feitas pelos dois usuários sobre

os itens do ambiente. As avaliações dos usuários podem ser representadas por uma matriz de avaliações  $A: U \times I$ , onde  $U$  representa os usuários e  $I$  os itens, conforme a Tabela 3.

**Tabela 3: Matriz de avaliações.**

	$i_1$	$i_2$	$i_3$	$i_4$	$i_5$
$u_1$	2		3	2	3
$u_2$	4		4		5
$u_3$	1	4	3		
$u_4$		2		4	5

Com a matriz de avaliações, é possível calcular a similaridade entre os usuários através da seguinte equação:

$$w_{a,b} = \frac{\sum_{i=1}^m (r_{a,i} - \bar{r}_a)(r_{b,i} - \bar{r}_b)}{\sqrt{\sum_{i=1}^m (r_{a,i} - \bar{r}_a)^2 \sum_{i=1}^m (r_{b,i} - \bar{r}_b)^2}}$$

**Equação 1: Correlação de Pearson entre dois usuários.**

Onde,  $w_{a,b}$  é a correlação entre os usuário  $a$  e  $b$ ,  $m$  é o número de itens avaliados em comum pelos dois usuários,  $r_{a,i}$  é a avaliação feita pelo usuário  $a$  para o item  $i$  e  $\bar{r}_a$  é a média das avaliações de  $a$ . A correlação é representada na escala [-1,1] e somente os itens avaliados pelos dois usuários são usados no cálculo da correlação entre eles. Com isso, a similaridade entre os usuários pode ser representada por uma matriz de similaridades  $W: U \times U$ , conforme a Tabela 4.

**Tabela 4: Matriz de similaridades.**

	$u_1$	$u_2$	$u_3$	$u_4$
$u_1$	-	0,6	0,8	0,2
$u_2$	0,6	-	-0,2	0,1
$u_3$	0,8	-0,2	-	-0,3
$u_4$	0,1	0,2	-0,3	-

### 4.2.1.2 Filtrar vizinhos

Depois de calculada a similaridade entre os usuários, é preciso selecionar os vizinhos que farão parte do cálculo de recomendações. Os vizinhos podem ser escolhidos através de filtros na matriz de similaridades. Entre os filtros possíveis, pode-se selecionar, por exemplo: os 10 usuários com maior correlação; todos os usuários com correlação maior que 0,2; entre outros. Selecionando-se como vizinhos todos os usuários com correlação maior que 0,2, ficamos com a seguinte lista de vizinhos:

**Tabela 5: Lista de vizinhos dos usuários.**

Usuário	Vizinho	Similaridade
$u_1$	$u_2$	0,6
$u_1$	$u_3$	0,8
$u_2$	$u_1$	0,6
$u_2$	$u_4$	0,2
$u_3$	$u_1$	0,8
$u_4$	$u_2$	0,2

### 4.2.1.3 Predição de avaliação

Com a lista de vizinhos e os níveis de similaridade, é possível prever as avaliações que o usuário faria para os itens que ele ainda não avaliou. A similaridade de um usuário com cada usuário do ambiente é utilizada para dar peso em suas recomendações. A predição da avaliação  $P_{a,i}$  de um item  $i$  para um usuário  $a$ , é calculada com base nas avaliações feitas para esse item por todos os usuários vizinhos ao usuário  $a$ , utilizando a similaridade  $w_{a,b}$  como peso principal da recomendação, conforme a Equação 2.

$$P_{a,i} = \bar{r}_a + \frac{\sum_{b=1}^n w_{a,b} * (r_{b,i} - \bar{r}_b)}{\sum_{b=1}^n |w_{a,b}|}$$

**Equação 2: Predição da avaliação do item  $i$  para o usuário  $a$ .**

Onde,  $\bar{r}_a$  e  $\bar{r}_b$  são as médias das avaliações dos usuários  $a$  e  $b$ , respectivamente e  $r_{b,i}$  é a avaliação do usuário  $b$  para o item  $i$ .

Com essa equação, se o usuário  $A$  é muito similar ao usuário  $B$ , as opiniões de  $A$  terão grande importância nas recomendações de  $B$ . Depois de fazer isso, é gerada uma lista de recomendações para o usuário, representada pelos valores em negrito na Tabela 6.

**Tabela 6: Recomendações para os usuários.**

	$i_1$	$i_2$	$i_3$	$i_4$	$i_5$
$u_1$	2	<b>3</b>	3	2	3
$u_2$	4		4	<b>3</b>	5
$u_3$	1	4	3	<b>2</b>	<b>4</b>
$u_4$	<b>3</b>	2		4	5

Os valores em branco na tabela indicam valores que não puderam ser preditos, por falta de dados suficientes entre os usuários, ou por serem pontos de corte, eliminados após passar por filtros de acordo com a necessidade do sistema.

A seguir será apresentado a Etapa 2 do modelo que trabalha com a Rede de Confiança para gerar recomendações.

## 4.2.2 Etapa 2: Rede de Confiança

Como proposta de ampliação da recomendação tradicional, é utilizada a Rede de Confiança do usuário para gerar novas predições ao usuário. Para isso, três passos são importantes:

- i. *Confiança direta*: O usuário confia em outros indivíduos criando sua Rede de Confiança direta;
- ii. *Propagação da confiança*: É propagada a confiança, a partir da confiança direta dele, para usuários que não possuem relacionamentos diretos, ampliando a rede;
- iii. *Prever avaliações*: O nível de confiança é aplicado nas avaliações dos itens que ele ainda não avaliou, para que esses itens possam ser inseridos na recomendação final.

#### 4.2.2.1 Confiança direta

O passo inicial para estabelecer a Rede de Confiança do usuário é a confiança direta dele. Essa confiança direta pode ser estabelecida de dois modos: explícito ou implícito. Nessa pesquisa são avaliados os dois modos separadamente, detalhados no Capítulo 6 - Experimentos e Resultados.

No modo explícito, o próprio usuário indica em que nível confia em outro usuário. Já no modo implícito, o sistema infere a confiança a partir de alguns fatores observados do usuário. Para isso, diferentes abordagens podem ser utilizadas, tais como: técnicas de correlação, análise de *clusters*, Sistemas de Reputação (CRUZ *et al.*, 2007), etc.

A confiança direta do usuário pode ser representada pela Figura 16, onde a seta indica a direção da confiança.




Figura 16: Confianças diretas dos usuários.

#### 4.2.2.2 Propagação da confiança

A partir da Rede de Confiança direta, é possível, utilizando métricas de confiança, propagar a confiança e estabelecer novas relações entre usuários. Para propagar a confiança,

foram desenvolvidas algumas métricas, detalhadas na Seção 3.2.4, onde, por exemplo, a métrica da Propagação Direta (Seção 3.2.4.1) objetiva encontrar a relação: se  $A$  confia em  $B$  e  $B$  confia em  $C$ , então o sistema pode inferir a confiança de  $A$  para  $C$ .

Golbeck *et al.* (2003) desenvolveu um algoritmo para calcular o nível de confiança propagado, onde a confiança do usuário para o usuário é encontrada conforme a Equação 3.

---

**Equação 3: Fórmula para encontrar a confiança de um usuário para um usuário .**

Onde tem confianças diretas que confiam em . Quando calculada essa confiança, fica garantido que o valor da propagação terá como peso maior as confianças diretas do usuário. Com isso a Rede de Confiança com a propagação pode ser representada pela Figura 17.




Figura 17: Propagação de confiança, linhas pontilhadas indicam as confianças propagadas inferidas.

#### 4.2.2.3 Prever avaliações

A partir da Rede de Confiança, pode-se então prever as avaliações que o usuário faria sobre os itens com base nas confianças do usuário. Para isso, é preciso encontrar os indivíduos da Rede de Confiança que avaliaram itens em comum, para assim encontrar uma média das avaliações com o peso dos valores da confiança. Com esse objetivo, Golbeck (2006) criou uma fórmula básica para encontrar a predição das avaliações do item  $i$  para o usuário  $a$  que pode ser definida pela Equação 4.

$$P_{a,i} = \frac{\sum_{u=0}^n (C_{a,u} * r_{u,i})}{\sum_{u=0}^n C_{a,u}}$$

**Equação 4: Predição de avaliação pela confiança.**

Onde,  $a$  confia em  $n$  usuários que avaliaram o item  $i$ ;  $C_{a,u}$  é a confiança do usuário  $a$  para o usuário  $u$ ; e  $r_{u,i}$  é a avaliação do usuário  $u$  pelo item  $i$ .

Por exemplo:

- $A$  confia em  $B$  em  $0,5$
- $A$  confia em  $C$  em  $0,8$
- $B$  avaliou o item  $I$  em  $4$  estrelas
- $C$  avaliou o item  $I$  em  $2$  estrelas

Com isso, o cálculo da predição do item  $I$  para o usuário  $A$  fica assim:

$$P_{a,i} = \frac{(C_{a,b} * r_{b,i}) + (C_{a,c} * r_{c,i})}{C_{a,b} * C_{a,c}} = \frac{(0,5 * 4) + (0,8 * 2)}{0,5 + 0,8} = 2,77 \cong 3 \text{ estrelas}$$

Depois de geradas as predições por esse método, as recomendações geradas pela Filtragem Colaborativa e Rede de Confiança são agrupadas e estabelecidos filtros sobre elas para recomendar ao usuário apenas os itens mais relevantes. A seguir é apresentada como é feita a recomendação final para o usuário.

### 4.2.3 Recomendação final de itens

Essa é a fase final da recomendação, onde são agrupadas as recomendações geradas pela Filtragem Colaborativa e pela Rede de Confiança. A partir desse grupo de recomendações, é preciso filtrá-las e classificá-las para que as recomendações mais relevantes sejam sugeridas ao usuário.

Como exemplo de filtro das recomendações, algumas pesquisas (MASSA e AVESANI, 2004; GOLBECK, 2006; HERLOCKER, 2000) recomendam aos usuários somente os itens com

alto grau de avaliação predita, por exemplo, predições maiores que 3 de uma escala de 1 a 5. Esse critério também é muito visto em *sites* de comércio eletrônico, onde, por motivos óbvios, só é interessante recomendar itens que o usuário possa ter interesse em comprar.

Para a classificação das recomendações, alguns critérios podem ser adotados, como por exemplo: recomendar os itens pela ordem de maior predição calculada; recomendar primeiro as predições da Rede de Confiança; deixar o usuário decidir qual ordem mostrar; entre outras. A classificação auxilia o usuário a identificar quais informações dar prioridade na leitura.

#### **4.2.4 Propriedades da confiança no modelo**

O modelo de recomendação baseado na Rede de Confiança possui algumas propriedades características de confiança, que são:

- a) Desconfiança é representada por valor nulo ou negativo;
- b) Confiança é representada por valor positivo;
- c) Confiança é baseada em experiências passadas e depende do contexto. Os usuários devem ser capazes de identificar as atividades de outros usuários em contextos distintos;
- d) Confiança é transitiva, subjetiva e assimétrica;
- e) Somente confiança entre pessoas é tratada, não sendo tratada a confiança de grupos ou a confiança no sistema como um todo.

### **4.3 Domínio de aplicação**

Inicialmente, o modelo foi definido para a comunidade virtual ActivUFRJ (HILDEBRAND, 2006), o qual é utilizado para implementação do modelo. Porém, o modelo pode operar em qualquer ambiente que possua algumas características de comunidade virtual,



entre as características essenciais, deve apresentar um conjunto de: itens, pessoas, avaliações sobre itens e confianças diretas dos usuários.

Assim, o sistema deve ser composto de:

- **Um conjunto  $I$  de itens únicos**

$$I = \{i_1, i_2, i_3, \dots, i_m\}$$

Deve haver um índice único para itens, sejam modelos mais formais, como o ISBN<sup>4</sup> para livros, ou valores de auto-contagem de bancos de dados.

- **Um conjunto  $U$  de usuários únicos**

$$U = \{u_1, u_2, u_3, \dots, u_k\}$$

- **Um conjunto  $A_u$  de avaliações dos itens do conjunto  $I$  pelo usuário  $u$**

$$A_{u_1} = \{a_{i_1}, a_{i_5}, a_{i_6}, \dots, a_{i_m}\}, \text{ onde, } a_{im}: I \rightarrow [0,1]$$

O sistema deve permitir que o usuário possa expressar uma avaliação para cada item. Cada avaliação do usuário deve possuir uma escala definida, que pode ser uma escala discreta de  $[0,1]$  onde 0 indica que não gosta e 1 que gosta muito.

Por exemplo,  $A_{u_1} = \{a_{i_5} = 0.8\}$ , significa que o usuário 1 avaliou em 0.8 o item 5, uma avaliação perto do máximo significa que o usuário gosta muito do item. Um valor que não aparece significa que o usuário não avaliou o item. Se possuir várias avaliações do mesmo usuário para o mesmo item, considera-se apenas a mais recente.

- **Um conjunto  $C_u$  das confianças diretas do usuário  $u$**

$$C_{u_1} = \{u_2, u_4, u_7, \dots, u_n\}, \text{ onde, } u_n: U \rightarrow [0,1]$$

Cada usuário deve ter a possibilidade de expressar sua confiança em outra pessoa do sistema. Essa confiança pode ser expressa em níveis diferentes. Esse nível deve possuir uma

---

<sup>4</sup> ISBN - *International Standard Book Number* - é um sistema internacional padronizado que identifica numericamente os livros segundo o título, o autor, o país, a editora, individualizando-os inclusive por edição.

escala definida, que pode ser uma escala discreta de  $[0,1]$  onde 0 indica desconfiança e 1 indica que confia completamente.

Por exemplo,  $(1, 2, 0.2)$ , indica que o usuário 1 confia em 0.2 no usuário 2, uma indicação baixa de confiança significa que o usuário confia pouco no usuário 2. Se existir várias indicações de confiança entre os mesmos usuários é considerada apenas a indicação de confiança mais recente.

Resumidamente, para que o modelo possa ser adotado em um ambiente virtual, é necessário que as informações sejam captadas da maneira como mostra o diagrama de relacionamento na Figura 18.

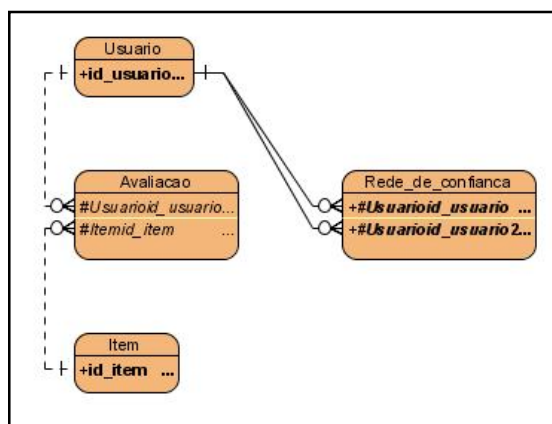


Figura 18: Diagrama entidade-relacionamento das informações necessárias para aplicação do modelo.

## 4.4 Considerações finais

Com a grande quantidade de informações presentes hoje na Internet, é cada vez mais difícil encontrar informações relevantes rapidamente. Com isso, torna-se cada vez mais necessário adotar novas práticas para auxiliar o usuário no processo de encontrar informações interessantes. Com esse propósito, nesse capítulo foi apresentado um modelo de recomendação de itens onde são levados em consideração, dois fatores: a similaridade entre usuários através de itens avaliados (Filtragem Colaborativa) e a confiança expressa pelo usuário em outros usuários (Rede de Confiança).

Porém, para que as redes de confiança sejam criadas, faz-se necessário prover uma maneira dos participantes identificarem indivíduos confiáveis nas comunidades virtuais, e se sentirem motivados a participar e contribuir com a comunidade, recebendo recomendações apropriadas com base nas avaliações feitas por pessoas em quem eles confiam.

Esse capítulo apresentou um modelo de Sistema de Recomendação baseada na confiança do usuário. Esse modelo tem como objetivo auxiliar o processo de indicar itens que sejam relevantes através de recomendações.

No próximo capítulo é apresentada a implementação desse modelo sob a forma de um protótipo, em um ambiente computacional que apóia a criação de redes de confiança pelo usuário.

## Capítulo 5

# Especificação e Implementação do Protótipo

“A perfeição não consiste na multiplicidade de coisas feitas, mas no fato de serem bem feitas.”

*São Vicente de Paulo*

Visando consolidar e validar as proposições desta dissertação, foi construído um protótipo de sistema cujo objetivo é recomendar filmes para usuários de uma comunidade. Foi inserido dentro do ActivUFRJ uma comunidade de filmes e um módulo de recomendações para que os usuários pudessem ajustar as recomendações recebidas.

## 5.1 Introdução

Com a finalidade de analisar a validade da hipótese desse trabalho, foi desenvolvido um protótipo baseado no modelo proposto no Capítulo 4, mais especificamente com interesse nas avaliações e Rede de Confiança dos usuários.

O protótipo utiliza o ActivUFRJ como base e integra novas funcionalidades a ele, com a finalidade de se adequar às necessidades da aplicação do modelo, definidas na Seção 4.3, tornando possível a recomendação baseada na confiança do usuário.

## 5.2 Visão geral do ActivUFRJ

O Ambiente Colaborativo de Trabalho Integrado e Virtual da UFRJ - ActivUFRJ (HILDEBRAND, 2006) é um portal de comunidades virtuais que foi desenvolvido com o objetivo de facilitar a formação e a manutenção de comunidades de interesses na UFRJ, para proporcionar o encontro entre grupos heterogêneos de pessoas que possam ter interesse pelo mesmo tema dentro da universidade. A UFRJ foi escolhida como objeto de estudo inicial desse projeto, por possibilitar um ambiente adequado para o compartilhamento de conhecimentos e experiências entre alunos, professores, pesquisadores e funcionários.

O projeto ActivUFRJ pertence ao grupo GINAPE do NCE e atualmente pode-se dizer que ele é uma versão BETA para um projeto maior, servindo como laboratório para diversos estudos, envolvendo: Redes Sociais, Combinação Social, Sistemas de Reputação, comunidades virtuais de aprendizagem, Sistemas de Recomendação, entre outras. Atualmente o grupo está unindo esforços, com outras áreas do conhecimento, para migrar o projeto ActivUFRJ para os ideais de PLE (*Personal Learning Environments*) e *Web2.0*. A ideia de PLE acentua a importância do indivíduo na organização do seu próprio aprendizado e com a *Web2.0* têm-se mais ferramentas para potencializar a colaboração e construção conjunta de conhecimento.

### 5.2.1 Estrutura base do ActivUFRJ

O modelo de desenvolvimento do ActivUFRJ é baseado em três entidades principais: Usuário, Comunidade e Artefato. Podendo ser especificados como sendo:

- *Usuário*: representa cada pessoa dentro do sistema através da sua página de perfil, sendo um conjunto  $U$  de  $k$  distintos usuários:  $U = \{u_1, u_2, \dots, u_k\}$ ;
- *Artefato*: representa qualquer tipo de material indicado por um membro da comunidade para a consulta, e avaliação dos demais membros, sendo um conjunto  $A$  de  $n$  distintos itens:  $A = \{a_1, a_2, \dots, a_n\}$ ;
- *Comunidade*: representa o espaço de encontro e de compartilhamento de artefatos, entre pessoas que tenham interesse em um mesmo tema, sendo um conjunto  $C$  de  $m$  distintas comunidades:  $C = \{c_1, c_2, \dots, c_m\}$ ;

Em seguida são apresentadas as telas principais do ambiente, bem como suas funcionalidades.

### 5.2.2 Minha página

Nesse módulo são disponibilizadas as informações gerais do usuário bem como atalhos para as principais funcionalidades do ambiente, como pode ser visto na Figura 19. As ferramentas desse módulo são:

- *Minhas comunidades*: Exibe as comunidades que o usuário criou ou participa;
- *Meus Artefatos*: Exibe os artefatos que o usuário criou ou está disponibilizando;
- *Rede de Confiança*: Exibe os membros que fazem parte da Rede de Confiança explícita;
- *Recomendações*: Mostra as recomendações de novos artefatos;

- *Minhas mensagens*: Possibilita ao usuário se comunicar com outros usuários da comunidade;
- *Estatísticas*: Mostra algumas estatísticas do usuário, entre elas, quantidade de comunidades e artefatos criados, número de acessos, último acesso e data de registro;
- *Meus recados*: Exibe recados recebidos de outros usuários;
- *Minhas avaliações*: Lista todas as avaliações feitas aos artefatos.



Figura 19: Página de perfil do usuário no ActivUFRJ.

### 5.2.3 Página do usuário

Na página de cada usuário são disponibilizados seus dados pessoais, histórico de suas mensagens, seus artefatos publicados, e a relação de comunidades em que participa, como mostra a Figura 20. As ferramentas desse módulo são:

- *Enviar mensagem*: Permite que envie uma mensagem particular para o usuário;
- *Indicar*: Serve para indicar o usuário para outro da comunidade;
- *Adicionar à Rede de Confiança*: Indicar um grau de confiança explícito ao usuário;
- *Enviar recado*: Permite enviar uma mensagem pública, menos informal;

- *Avaliações do usuário*: Mostra a lista de avaliações feitas pelo usuário.



Figura 20: Página do Usuário no ActivUFRJ.

## 5.2.4 Página da comunidade

A página da comunidade é o espaço onde os usuários podem cadastrar eventos, avisos, acessar o perfil dos outros membros, e consultar as páginas dos artefatos publicados. Como mostra a Figura 21. As funcionalidades desse módulo são:

- *Indicar esta comunidade*: Permite indicar diretamente a comunidade a outro usuário;
- *Cadastrar artefato*: Permite que os usuários do ambiente possam cadastrar artefatos na comunidade;
- *Eventos*: Permite cadastrar eventos relacionados aos assuntos da comunidade;
- *Avisos*: Painel de avisos gerais da comunidade;
- *Artefatos*: Exibe todos os artefatos cadastrados na comunidade;
- *Usuários*: Lista todos os usuários cadastrados na comunidade;
- *Estatísticas*: Apresenta algumas estatísticas da comunidade;



- *Comunidades Afins*: Permite criar e visualizar comunidades que tenham relação à comunidade em foco.



Figura 21: Página da Comunidade no ActivUFRJ.

## 5.2.5 Página do artefato

Artefato representa qualquer tipo de material digital ou não indicado por um membro da comunidade para a consulta e avaliação dos demais membros. Esse material pode ser, por exemplo, um documento textual (artigos científicos, tese, livro), uma base de dados, um software, um vídeo, etc..

A página de um artefato, ilustrada na Figura 22, possui as seguintes informações: nome do artefato, descrição, nome da pessoa que o publicou, data de publicação, histórico de atualizações, endereço para acesso ou *download* do artefato, e as seguintes funcionalidades:

- *Avaliações*: Permite aos membros dar uma nota, escala de 1 a 5 estrelas, e deixar um comentário sobre o artefato;
- *Meta-avaliação*: Permite ao usuário criticar a avaliação de outro usuário;
- *Comentários*: Permite aos usuários inserirem comentários;
- *Estatísticas*: Apresenta algumas estatísticas quantitativas;

- *Fórum*: Permite aos usuários criar um fórum de discussão.



Figura 22: Página de um Artefato no ActivUFRJ.

## 5.2.6 Tecnologias utilizadas no ActivUFRJ

O ActivUFRJ foi desenvolvido em ASP.NET que é uma plataforma da *Microsoft* para o desenvolvimento de aplicações *Web* e é o sucessor da tecnologia ASP. Além disso, o ASP.NET possibilita a utilização do AJAX (*Asynchronous Javascript and XML*) que é o uso sistemático de tecnologias providas por navegadores, como *Javascript* e *XML*, para tornar páginas mais interativas com o usuário, utilizando-se de solicitações assíncronas de informações.

O sistema de gerenciamento de banco de dados do ActivUFRJ é o *MySQL*, que utiliza a linguagem SQL (*Structured Query Language*) como interface. Esse banco de dados é um Software livre.

## 5.3 O Protótipo: Funcionalidades agregadas

Para tornar possível a utilização do ActivUFRJ com as funcionalidades necessárias para aplicação do modelo, foram agregados 3 módulos à comunidade: Avaliação de Artefato, Rede de Confiança e Recomendações, detalhados a seguir.

### 5.3.1 Avaliação de artefato

A atividade de avaliação de artefatos é realizada através do formulário de avaliação do artefato, apresentado na Figura 23, onde o usuário indica uma nota que reflete a sua opinião geral do artefato, na escala de 1 a 5 estrelas, e escreve um comentário sobre a sua avaliação. Além disso, o usuário pode ter acesso a outras avaliações feitas por outros usuários, através da aba “Ler Avaliações”.



Avaliar	Ler Avaliações
Nome do Artefato:	Shrek
Descrição do Artefato:	Nas telas em 2001, número 33 em arrecadação com US\$ 267,665,000
Nota:	★★★★★
Comentário:	<input type="text"/>
<input type="button" value="Enviar"/> <input type="button" value="Cancelar"/>	

Figura 23: Formulário de avaliação do artefato no ActivUFRJ.

A Figura 24 representa as ações necessárias para avaliar um artefato.

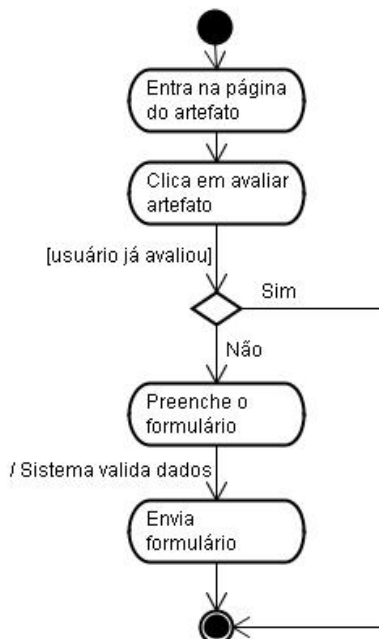


Figura 24: Diagrama UML de atividades da funcionalidade "Avaliar artefatos".

### 5.3.2 Rede de Confiança

Valores de confiança em nosso modelo são limitados dentro de cada área de interesse e são independentes dos valores em outras áreas de interesse. É difícil representar a natureza qualitativa da confiança com precisão contínua de valores. Deste modo, níveis discretos de confiança são usados neste protótipo.

Dois tipos de confiança foram utilizados no protótipo:

1. *Nível de confiança geral*: significa um valor geral que a pessoa dignifica para o outro usuário, e está relacionado a confiança do quanto a pessoa representa para outra. O nível de confiança geral fica representado em uma escala de 0 a 5 estrelas, onde 0 representa desconfiança e 5 total confiança.
2. *Nível de confiança por área de interesse*: é o nível de confiança contextualizado para a outra pessoa, sendo independente da confiança geral e independente entre áreas de

interesse distintas. Os níveis da confiança contextualizada foram definidos conforme a Tabela 7.

**Tabela 7: Níveis de confiança contextualizada.**

Valor	Significado	Descrição
0	Nada	Completamente não confiável (desconfiança).
1	Pouco	Não confia em quase nada do que avaliou.
2	Médio	Confia em algumas coisas do que avaliou.
3	Muito	Confia completamente nas avaliações do usuário.

Na Figura 25, tem-se um exemplo do usuário "*Leonardo Zanette*" colocando a usuária "*Claudia Paranhos*" e indicando nível de confiança geral 5 (muito confiável) e para o contexto "Filmes" o nível "Médio".

The screenshot shows a web interface titled "+ Rede de Confiança" with a speech bubble icon. Below the title, it says "Confiança em Claudia Paranhos". There is a section for "Nível de Confiança Geral" with five yellow stars. Below that, there is a field for "Área de interesse:" with the text "Filmes" and an "Adicionar" button. At the bottom, there is a table with three columns: "Área de Interesse", "Confiança na Área", and "Opções".

Área de Interesse	Confiança na Área	Opções
Filmes	Média	Salvar Excluir
Avaliação de filmes	Alta	Salvar Excluir

**Figura 25: Tela de exemplo para colocar uma pessoa na Rede de Confiança.**

Para representar as atividades necessárias para colocar uma pessoa na Rede de Confiança é apresentada na Figura 26 com o diagrama de atividades aplicado no protótipo.

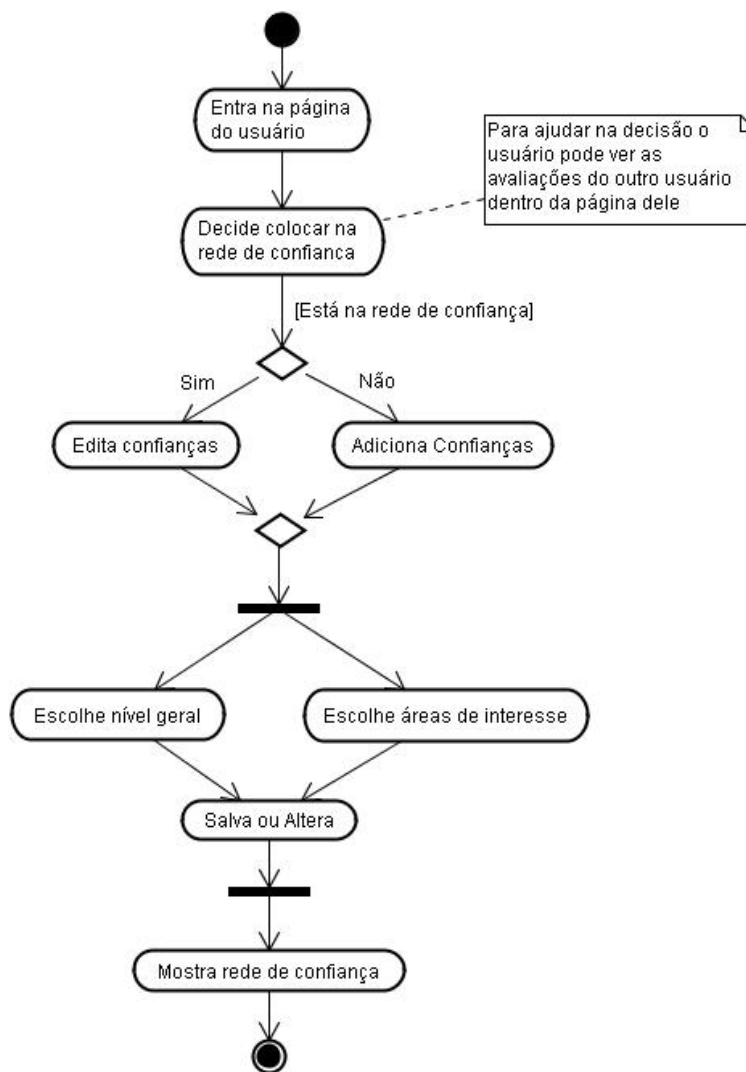


Figura 26: Diagrama UML de atividades da funcionalidade "Colocar na Rede de Confiança".

### 5.3.3 Recomendações geradas

A partir da análise de perfil dos usuários, mais detalhes no Capítulo 6, são geradas recomendações e listadas por ordem de interesse na página do usuário. Essas recomendações permitem o usuário entrar no artefato e também criticar as recomendações recebidas, indicando se concordou ou não concordou com a avaliação predita pelo modelo. A Figura 27 apresenta as recomendações com as respectivas predições geradas para um usuário.



Figura 27: Tela das recomendações recebidas pelo usuário, com a possibilidade de criticar as avaliações preditas.

## 5.4 Estrutura do protótipo

A Figura 28 apresenta o Diagrama UML de Casos de Uso que ilustra as funcionalidades agregadas descritas anteriormente.

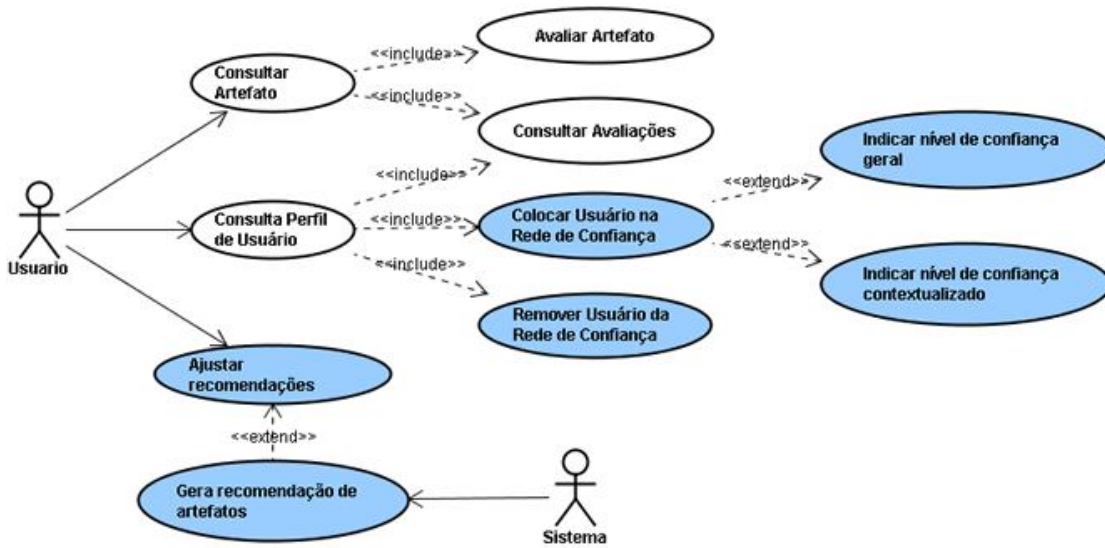


Figura 28: Diagrama UML de casos de uso das funcionalidades agregadas.



### 5.4.1 Diagrama de classes

A Figura 29 apresenta o Diagrama UML de Classes com a estrutura das funcionalidades agregadas ao ActivUFRJ.

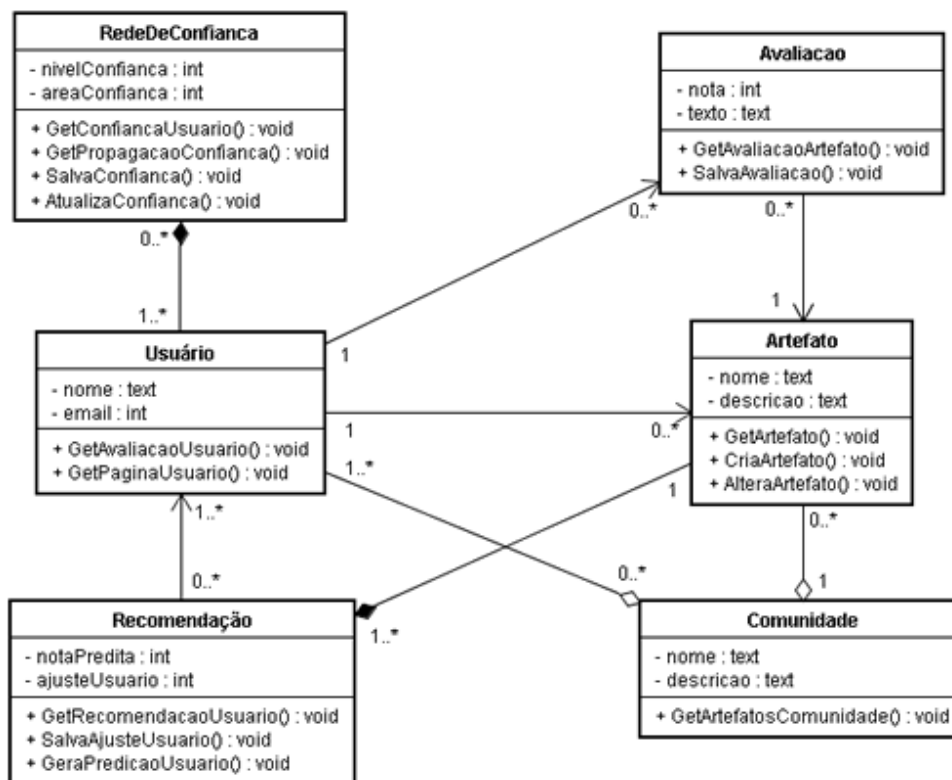


Figura 29: Diagrama UML de classes representando a estrutura das funcionalidades agregadas ao ActivUFRJ.

### 5.4.2 Casos de uso

Caso de Uso 01	Avaliar artefato
Descrição:	Permite que o usuário avalie um artefato do ambiente.
Atores:	Usuário
Pré-condições:	Entrar na página do artefato
Ações:	<ol style="list-style-type: none"> <li>1. Usuário escolhe a avaliação para o artefato;</li> <li>2. Usuário digita um texto descritivo de sua avaliação;</li> <li>3. Sistema valida os dados, caso estejam corretos, insere a avaliação.</li> </ol>
Pós-condições:	<ol style="list-style-type: none"> <li>1. Artefato recebe a avaliação.</li> </ol>

<b>Caso de Uso 02</b>	<b>Colocar na Rede de Confiança</b>
<b>Descrição:</b>	Permite que o usuário coloque outros usuários em sua Rede de Confiança.
<b>Atores:</b>	Usuário
<b>Pré-condições:</b>	Visitar a página do usuário que quer colocar na Rede de Confiança.
<b>Ações:</b>	<ol style="list-style-type: none"> <li>1. Usuário escolhe outro usuário para colocar na Rede de Confiança;</li> <li>2. Sistema verifica se o usuário já possui confiança para a pessoa escolhida, caso possua, sistema mostra para edição as confianças estabelecidas;</li> <li>3. Usuário escolhe a "Confiança geral" para a pessoa;</li> <li>4. Usuário digita uma "área de interesse" para inserir a confiança contextualizada;</li> <li>5. Usuário insere o nível de confiança para a "área de interesse";</li> <li>6. Sistema valida os dados, caso estejam corretos, cadastra a Rede de Confiança.</li> </ol>
<b>Pós-condições:</b>	<ol style="list-style-type: none"> <li>1. Rede de Confiança criada.</li> </ol>
<b>Exceções:</b>	<ul style="list-style-type: none"> <li>• <b>E-01:</b> Caso falte colocar a "confiança geral" uma tela contendo a mensagem de erro é apresentada. O usuário escolhe a opção OK e retorna ao formulário de cadastro.</li> <li>• <b>E-02:</b> Caso falte escolher o nível da confiança contextualizada, uma tela com uma mensagem é apresentada, possibilitando ao usuário excluir ou escolher a confiança contextualizada.</li> </ul>

<b>Caso de Uso 03</b>	<b>Recomendar artefatos</b>
<b>Descrição:</b>	Sistema fornece recomendações de artefatos, aos usuários, baseados em algoritmos de recomendação e na Rede de Confiança.
<b>Atores:</b>	Sistema
<b>Pré-condições:</b>	Ser usuário do sistema, ter feito o Caso de Uso 01 ou ter feito o Caso de Uso 02
<b>Ações:</b>	<ol style="list-style-type: none"> <li>1. Sistema gera recomendações de artefatos que possam interessar o usuário.</li> </ol>
<b>Pós-condições:</b>	<ol style="list-style-type: none"> <li>1. Usuário recebe recomendações de artefatos.</li> </ol>

<b>Caso de Uso 04</b>	<b>Ajustar recomendações</b>
<b>Descrição:</b>	Sistema permite ao usuário ajustar as recomendações recebidas.
<b>Atores:</b>	Usuário
<b>Pré-condições:</b>	Caso de Uso 03
<b>Ações:</b>	<ol style="list-style-type: none"> <li>1. Usuário verifica as recomendações recebidas e concorda ou não com a avaliação predita pelo sistema;</li> </ol>
<b>Pós-condições:</b>	<ol style="list-style-type: none"> <li>1. Recomendação é exibida com o nível ajustado;</li> <li>2. Ajuste utilizado para refinar o Caso de Uso 03</li> </ol>

## 5.5 Considerações finais

A escolha do ActivUFRJ como a plataforma de desenvolvimento para implementação do protótipo, foi devido principalmente a ser uma comunidade virtual com muitas características necessárias para aplicação do modelo, necessitando apenas da inserção de algumas funcionalidades. Dessa forma, o ambiente ActivUFRJ muito contribuiu para isso, devido às funcionalidades disponíveis, código pré-existente, experiência em programação para *Web*, continuidade e ampliação do projeto ActivUFRJ.

No protótipo desenvolvido, outras funcionalidades previstas no modelo conceitual não foram implementadas, entre elas, criar a Rede de Confiança propagada do usuário.

Trabalhos com Sistema de Reputação, Redes sociais e Combinação Social, estão em desenvolvimento em outras dissertações e serão implementados no ambiente, podendo complementar o modelo conceitual proposto.

Algumas ferramentas de comunicação, como: fórum, *chat* e recados, estão sendo desenvolvidas com o objetivo de possibilitar maior interação entre os membros da comunidade.

Este capítulo apresentou as funcionalidades agregadas ao ActivUFRJ e suas especificações para implementação, com o objetivo de experimentar o modelo de recomendação com Redes de Confiança.

No próximo capítulo é apresentado os experimentos e resultados da aplicação do protótipo em um grupo de voluntários bem como avaliações do modelo quando comparado com a Filtragem Colaborativa tradicional.

## Capítulo 6

# Experimentos e Resultados

---

“A perfeição é feita em pequenos detalhes – não é apenas um detalhe.”

*Michelangelo*

Neste capítulo são descritos os estudos realizados para verificar a viabilidade do modelo proposto, que teve como objetivo validar a hipótese que orienta essa dissertação. Em cada Estudo é feita uma descrição da metodologia aplicada, os métodos de investigação utilizados e a interpretação dos resultados obtidos.

## 6.1 Descrição dos experimentos

Durante a realização dessa pesquisa, dois estudos foram fundamentais para validação do modelo proposto, cada estudo foi conduzido baseado nos seguintes objetivos:

**Estudo 1:** O primeiro estudo teve como objetivo principal validar o modelo proposto. Para isso, foram feitos três estudos de caso utilizando uma base de dados real, com milhares de dados históricos, para avaliar a viabilidade do modelo proposto. Esse estudo foi conduzido a partir da análise *off-line* dos dados, sem participação de usuários.

Os objetivos envolvidos nesse primeiro estudo são:

- Verificar a aplicação do modelo em uma base de dados real;
- Verificar a eficácia do modelo levando-se em consideração as métricas de cobertura e precisão;
- Verificar a validade do modelo pela comparação de médias com o teste de hipóteses Z;
- Verificar a possibilidade de gerar implicitamente uma Rede de Confiança dos usuários;
- Verificar a diminuição dos problemas de Sistemas de Recomendação, tais como: problema do novo usuário, problema do primeiro avaliador e problema das matrizes esparsas.

**Estudo 2:** O segundo estudo foi utilizado para validação final da proposta com a participação direta de um grupo de pessoas em um protótipo desenvolvido na comunidade virtual ActivUFRJ. Os processos metodológicos conduzidos nesse segundo estudo envolvem a implementação, aplicação do modelo e a análise de um questionário aplicado aos participantes.

Os objetivos envolvidos nesse segundo estudo são:

- Verificar a aplicação do modelo em uma comunidade virtual com usuários ativos, utilizando como protótipo o ActivUFRJ;
- Verificar a eficácia do modelo levando-se em consideração as métricas de cobertura e precisão;
- Verificar a validade do modelo pela comparação de médias com o teste de hipóteses Z;
- Verificar junto aos usuários da comunidade a satisfação pelos itens recomendados.

A seguir são apresentadas as métricas para avaliação das recomendações dos dois Estudos conduzidos nessa pesquisa.

### **6.1.1 Métricas para avaliação das recomendações**

Para avaliar se o modelo está agregando uma maior confiabilidade nas recomendações, são feitos testes em três dimensões: cobertura, *MAE* e teste de hipóteses Z, descritas a seguir.

#### **6.1.1.1 Cobertura**

A cobertura é medida em dois aspectos: cobertura de usuários e cobertura de itens.

A cobertura de usuários refere-se ao percentual de pessoas da comunidade que receberam recomendações depois de aplicado o algoritmo.

A cobertura de itens é o percentual de itens que foram recomendados aos usuários em relação ao total de itens existentes na base de dados.

#### **6.1.1.2 Precisão da predição**

As pesquisas de Sistemas de Recomendação têm utilizado diversas métricas para avaliar a precisão dos Sistemas de Recomendação. O Erro Absoluto Médio (*MAE* - *Mean Absolute Error*) está entre as preferências dos pesquisadores sendo a métrica mais utilizada (SARWAR *et al.*, 2001). O *MAE* mede o desvio das recomendações em relação ao seu verdadeiro valor – a

avaliação real de um utilizador específico. Para cada par (avaliação real, predição)  $(A_i, P_i)$  esta métrica calcula o erro absoluto entre estes,  $E = |A_i - P_i|$ . Realizando a média desse erro sobre cada predição é que se obtém o índice *MAE*. Quanto mais próximo de zero for o *MAE*, mais precisas são as recomendações.

O *MAE* é representado pela equação:

$$MAE = \frac{1}{n} * \sum_{i=1}^n |S_i - R_i|$$

**Equação 5: *MAE* - Erro Absoluto Médio, cálculo da precisão da avaliação.**

### 6.1.1.3 Teste de Hipóteses Z

Com o objetivo de validar o modelo com uma métrica mais reconhecida no meio científico, foi escolhido o teste de hipóteses Z, por ser uma aplicação da estatística muito difundida e permitir confirmar a eficácia dos métodos adotados no experimento. Para realizar esse teste, algumas estratégias devem ser adotadas com relação: dimensionamento da amostra, as hipóteses que serão estabelecidas e o nível de significância, detalhados a seguir.

*Dimensionamento da amostra:* Para realizar o teste de hipóteses Z, o primeiro passo é definir o tamanho da amostra. Isso é feito realizando a estimação por intervalo com a confiança e a precisão desejadas, através da equação:

$$n = \left(\frac{z}{E}\right)^2 (\sigma_1^2 + \sigma_2^2)$$

Onde  $z = 1,96$  para o nível de significância  $\alpha = 0,05$ ; trabalhando com o erro máximo onde  $E = |(\overline{X}_1 - \overline{X}_2) - (\mu_1 - \mu_2)|$ , com  $\mu_1 - \mu_2 = 0$ ,  $\overline{X}_1 - \overline{X}_2$  a diferença das médias da população e  $\sigma_1^2 + \sigma_2^2$  a soma das variâncias da população.

*Hipótese estatística:* Uma hipótese estatística é uma afirmativa a respeito de um parâmetro de uma distribuição de probabilidade. O primeiro passo é o estabelecimento das hipóteses: hipótese nula e hipótese alternativa.

*Hipótese Nula* ( ): A hipótese nula dessa pesquisa considera que as médias das avaliações preditas para o usuário é igual à média das avaliações reais do usuário.

*Hipótese Alternativa* ( ): E como hipótese alternativa, a média das avaliações preditas para o usuário é diferente das médias reais do usuário.

Cálculo do é o valor calculado a partir da amostra, que será usado na tomada de decisão. Para o caso de testes de médias, a estatística do teste é a variável padronizada Z, calculada pela seguinte equação:


$$Z = \frac{\bar{X} - \mu_0}{\frac{s}{\sqrt{n}}}$$

**Equação 6: Teste de hipóteses Z.**

O valor da estatística Z, é calculado supondo que a hipótese nula ( ) é verdadeira.

*Nível de significância:* é a região crítica onde é rejeitada. A área da região crítica é igual ao nível de significância , que estabelece a probabilidade de rejeitar quando ela é verdadeira. Nessa pesquisa será utilizado o nível de significância de 95 %, .

*Região de decisão:* Se o valor da estatística do teste estiver na região crítica, rejeita-se . Com nível de significância , o tabelado , então se estiver no intervalo , não rejeita-se . A Figura 30 representa a região crítica com as partes marcadas de cor diferente.



**Figura 30: Representação da região de decisão do teste de hipóteses Z.**



A seguir serão apresentados os estudos conduzidos e os resultados apresentados pelas métricas.

## 6.2 Estudo 1: Validação do modelo

O primeiro estudo tem como objetivo validar o modelo proposto através da sua aplicação em uma base de dados real. Além disso, analisar quais critérios devem ser levados em consideração para aplicação do modelo e a relevância na utilização da Rede de Confiança para recomendar itens.

Conforme Herlocker *et al.* (2004), avaliações de Sistemas de Recomendação podem ser realizadas com análises *off-line*, onde são utilizados conjuntos de dados históricos de um Sistema de Recomendação, na qual testes são feitos e métricas são analisadas.

Com isso, os experimentos desse estudo basearam-se em uma adaptação de uma base real, para comparar resultados das duas etapas do modelo (Filtragem Colaborativa e Rede de Confiança), atuando isoladamente e agrupadas. Para isso, três experimentos foram conduzidos:

Experimento 1: Filtragem Colaborativa utilizando o algoritmo *Pearson R*

Experimento 2: Rede de Confiança implícita utilizando o algoritmo *Pearson*

Experimento 3: Rede de Confiança implícita utilizando *Cluster k-means*

### 6.2.1 Base de dados experimental

Para a realização dos experimentos do Estudo 1, foi necessária uma base de dados com informações reais que possuíssem os seguintes requisitos:

- a) Grande quantidade de usuários;
- b) Grande quantidade de itens;
- c) Grande quantidade de avaliações sobre itens;
- d) Indicações de confiança entre usuários.

Porém, não foi possível encontrar uma base de dados que atendesse ao requisito “d” (Indicações de confiança entre usuários), com isso, optou-se pela adaptação da base de dados do *MovieLens* (MOVIELENS, 2003), gerando uma tabela de confianças implicitamente.

A base de dados *MovieLens* está referenciada em diversos artigos (HERLOCKER *et al.*, 2004; SARWAR *et al.*, 2000). Ela está disponibilizada para o uso acadêmico, e consiste de:

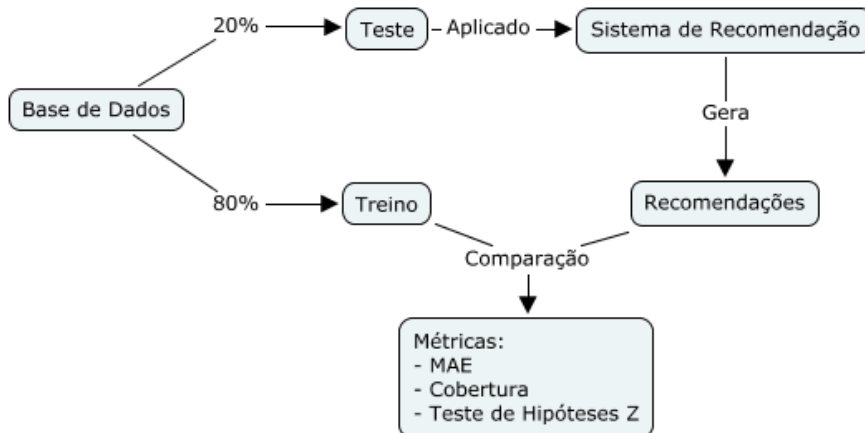
- a) 943 usuários;
- b) 1682 filmes;
- c) 100 mil avaliações de filme;

Uma vez que base de dados do *MovieLens* foi escolhida, necessitou-se adaptá-la para os testes com a Rede de Confiança do usuário. Portanto, foi necessário criar uma relação confianças diretas para os usuários da base de dados, de maneira implícita. A confiança implícita foi gerada a partir de dois métodos distintos, o primeiro foi pela correlação de *Pearson* e o segundo através da técnica de *cluster K-means*, explicados nos experimentos 2 e 3, respectivamente.

Além disso, para efeito de avaliação do modelo, as seguintes estratégias foram adotadas:

- As 100 mil avaliações foram divididas, de forma aleatória, em dois conjuntos diferentes: Treino e Teste. A porcentagem pela qual foi efetuada esta divisão foi, respectivamente, 80% e 20% do número total de avaliações;
- O conjunto Teste foi utilizado para aplicar o modelo e gerar as recomendações;
- O conjunto de recomendações geradas foi comparado com o conjunto Treino através das métricas de cobertura e precisão, descritas na Seção 6.1.1.

Sintetizando, a Figura 31 representa a estratégia aplicada para validação do modelo.



**Figura 31: Método para avaliação do modelo.**

Os conjuntos Teste e Treino são disponibilizados pelo *MovieLens*, representando conjuntos disjuntos, onde serão feitos os experimentos na base Teste e comparados com seu respectivo conjunto Treino.

Com isso, as configurações das bases de dados após a divisão ficaram conforme a Tabela 8.

**Tabela 8: Configuração da base de dados *MovieLens* após sua divisão em Teste e Treino. A coluna “Zeros” representa a porcentagem de filmes que não foram avaliados pelos usuários.**

	Total de avaliações	%	Usuários	Filmes	Zeros
<i>MovieLens</i>	100.000	100%	943	1682	93,70%
Teste	20.000	20%	462	1410	97,28%
Treino	80.000	80%	943	1650	94,96%

A seguir é apresentada uma avaliação inicial na base de dados Teste.

## 6.2.2 Avaliação da base de dados Teste

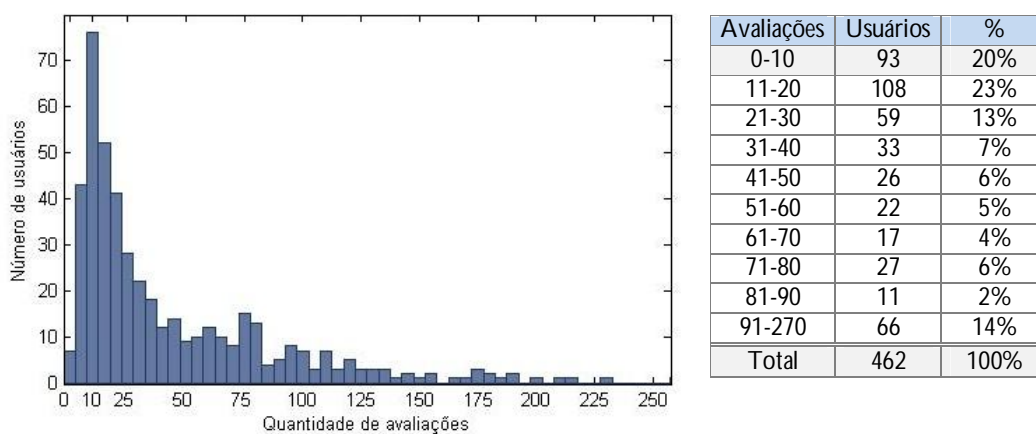
As avaliações iniciais na base de dados Teste, tem como objetivos:

- Evidenciar os problemas relativos aos Sistemas de Recomendação (Seção 2.6), que são: problema do novo usuário (Seção 2.6.1), problema do primeiro avaliador (Seção 2.6.2) e problema das matrizes esparsas (Seção 2.6.3).

- b) Analisar alguns dados quantitativos, referentes à quantidade de avaliações por usuários, distribuição das avaliações, quantidade de avaliações por filmes, entre outros.


#### Problema do novo usuário:

Novos usuários são aqueles que fizeram menos de 10 avaliações, na Figura 32, pode ser visto que 93 (20%) são usuários novos, sendo impossível gerar recomendações, pela Filtragem Colaborativa, para esse grupo de usuários.



**Figura 32: Número de avaliações feitas por usuários na base teste. Entre os usuários que fizeram avaliações, a média de avaliações por usuário é 43 e a mediana é 25.**

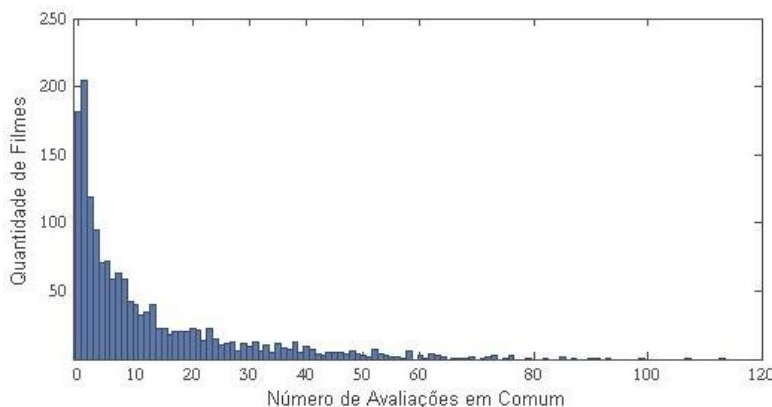
Por outro lado, a utilização da Filtragem Colaborativa é restrita, de acordo com Herlocker (2000), para que haja uma correlação significativa entre dois usuários, é necessário que os dois tenham no mínimo 10 itens avaliados em comum. A Figura 33 mostra a quantidade de pessoas que tem itens avaliados em comum com um usuário da base de dados.



**Figura 33: Distribuição da quantidade de avaliações que o Usuário 1 possui com outros usuários, no total ele avaliou 137 filmes.**

**Problema do primeiro avaliador:**

Quando se tem o objetivo de calcular a similaridade entre dois usuários, é muito importante a distribuição avaliações pelos itens da comunidade. A Figura 34, mostra a distribuição das avaliações, onde pode ser visto que 477 (28%) filmes receberam menos que 1 avaliação, fazendo com que esses itens não possam ser utilizados no cálculo da similaridade entre usuários.



Avaliações	Filmes	%
0	272	16%
1	205	12%
2 - 10	620	37%
11 - 20	252	15%
21 - 30	134	8%
31 - 40	87	5%
41 - 50	46	3%
51 - 60	30	2%
>60	36	2%
Filmes Avaliados	1410	84%
Total	1682	100%

**Figura 34: Ocorrência de avaliações do mesmo filme por diferentes usuários.**

Outro fator importante sobre a distribuição de avaliações, diz respeito à quantidade de vizinhos do usuário que avaliaram o mesmo item em comum, pois para efeito de cálculo de recomendação, pela Filtragem Colaborativa, é necessário que o mesmo filme tenha sido avaliado

por no mínimo 10 vizinhos do usuário. Com isso, filmes com menos de 10 avaliações não podem ser recomendados, representando 1097 filmes ou 65% da base de dados.

### Matrizes esparsas:

Na Figura 34, vê-se que 16% dos itens não receberam nenhuma avaliação, 12% receberam apenas 1 avaliação e o maior grupo, são os que foram avaliados de 2 a 10 vezes, representando 37%. Para ser calculada a similaridade entre duas pessoas, é muito importante a quantidade de itens avaliados no sistema. Faz uma grande diferença calcular a similaridade entre duas pessoas, quando a maioria das avaliações se concentra em poucos itens do sistema ou se as avaliações estão distribuídas pela maioria dos itens da base. Com isso, pode ser visto na Figura 35, a matriz de avaliações da base teste é muito esparsa (96,91%), e uma grande parte dos itens receberam poucas avaliações.

Nas comunidades virtuais com grande quantidade de usuários e de itens, é comum que a matriz usuário x avaliação seja esparsa, isso se deve pois é normal que os usuários avaliem uma pequena quantidade de artefatos do total existente, causando uma grande porcentagem de células vazias. Para calcular a correlação de *Pearson*, apenas itens que foram avaliados por duas ou mais pessoas são levados em consideração.





Figura 35: Dispersão das avaliações na base de dados Teste.

Também é interessante notar a distribuição de avaliações feitas pelos usuários. Na escala de 1 (ruim) a 5 (ótimo) das avaliações, 22% das avaliações foram a nota 5 (ótimo), 34% foram 4, 26% foram 3, 11% foram 2 e 7% foram 1 (ruim). A média das avaliações foi 3,54 e a mediana é 4.

Isso mostra que a maioria dos usuários avaliou os filmes com notas altas, podendo representar que eles avaliaram somente os filmes que mais gostavam.



**Figura 36: Dispersão dos valores de avaliações dos usuários.**

### 6.2.3 Experimentos realizados

Nessa Seção são apresentados os três experimentos realizados com o objetivo de testar o modelo proposto e comparar com os métodos tradicionais de recomendação. Os experimentos estão divididos em:

1. Filtragem Colaborativa tradicional (*Pearson R*),
2. Rede de Confiança direta (*Pearson*) e
3. Rede de Confiança direta (*Cluster K-means*).

Para a realização dos experimentos foi utilizada a análise *off-line*. Nesta análise são utilizados conjuntos de dados históricos de um Sistema de Recomendação, na qual testes são feitos e métricas são analisadas para comparações de resultados. Uma das vantagens da análise *off-line* é a realização de testes rápidos, pois não necessitam do envolvimento do usuário e podem ser facilmente repetidos.

#### 6.2.3.1 Experimento 1: Filtragem Colaborativa tradicional (*Pearson R*)

O primeiro experimento tem por objetivo observar a utilização da Filtragem Colaborativa tradicional na geração de recomendações. Para efeitos dessa pesquisa, será tratada

como Filtragem Colaborativa tradicional a aplicação da Filtragem Colaborativa com a utilização da técnica de *Pearson R*. Nessa técnica três passos são importantes:

1. Correlacionar o usuário com todos da comunidade e encontrar o peso de similaridade entre ele e cada usuário;
2. Filtrar os usuários com maior semelhança (vizinhos);
3. Inserir o peso de similaridade nas avaliações e computar as predições.


O coeficiente de *Pearson*, utilizado no primeiro passo da Filtragem Colaborativa mede a correlação ente duas pessoas. Esta correlação é representada por um número que varia entre -1, que indica ausência total de correlação, e 1 que indica forte correlação. A escolha do algoritmo de correlação *Pearson R*, foi motivada por alguns fatores:

- É um algoritmo muito testado e reconhecido para predição de similaridade em Sistemas de Recomendação, além de que, obteve melhores resultados na precisão e no tempo de computação em relação a outras técnicas (HERLOCKER, 2000);
- É um algoritmo de fácil entendimento, rápida execução no sistema e fácil programação.

A correlação de *Pearson* de um usuário *a* para outro usuário *b* é calculada de acordo com a Equação 1, detalhada na Seção 4.2.1.1.

Na Figura 37 pode-se ver a correlação entre o *Usuário 1* e todos os outros usuários da comunidade.





**Figura 37: Correlação *Pearson R* do usuário 1 sobre todos os outros da base de dados.**

Uma vez calculada a correlação de *Pearson* entre um usuário e todos os outros da comunidade, pode-se calcular a predição de avaliação dos itens não avaliados pelo usuário, pela Equação 2, detalhada na Seção 4.2.1.3.

#### 6.2.3.1.1 Método de pesquisa

Para efetivação do primeiro experimento, quatro passos foram necessários:

1. Escolha dos critérios mínimos para gerar recomendações;
2. Cálculo da correlação entre usuários com a base Teste;
3. Cálculo das recomendações com peso das correlações;
4. Análise dos resultados na base Treino.

Primeiramente foram escolhidos os critérios que seriam utilizados para gerar as recomendações. Esses critérios têm grande importância tanto na qualidade das recomendações quanto na cobertura de filmes e usuários que pode atingir. Com isso, foram analisados, separadamente, e escolhidos de acordo com duas necessidades principais: a primeira é que não devia atingir menos de 80% dos usuários da base de dados e a segunda, o erro médio não poderia ser superior a 0,4, esses valores de corte foram escolhidos com base a equivaler com a forma que as pesquisas na área tratam esses valores, segundo Herlocker (2004). Cabe ressaltar que esses testes iniciais foram feitos com a base Teste e comparados com a própria base Teste.

Estabelecidos esses dois critérios mínimos de qualidade, concluiu-se na utilização do nível de *Pearson* maior que 0,1, a utilização de no mínimo 25 avaliações de filmes em comum entre dois usuários para calcular a correlação de *Pearson* e a utilização de pelo menos 6 avaliações para itens na influência das recomendações. Os dados que motivaram essas escolhas estão nas figuras a seguir.




Figura 38: Cobertura e MAE quando alterado o nível de *Pearson*.

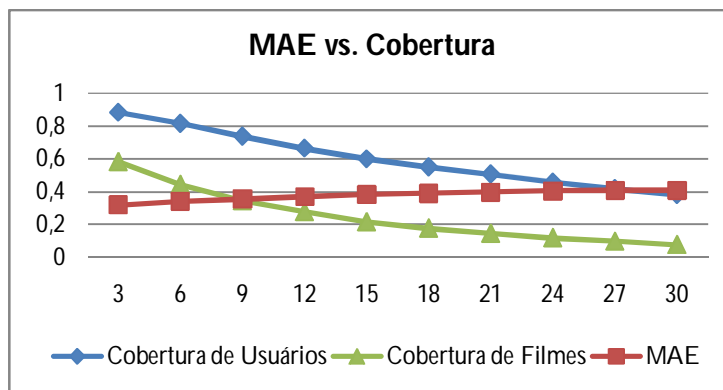



Figura 39: Cobertura e MAE quando alterado a quantidade de avaliações que influenciam na correlação entre dois usuários.



**Figura 40: Cobertura e MAE quando alterado o número de pessoas que influenciam nas recomendações.**

Estabelecidos os critérios, foram geradas as recomendações através da técnica de Filtragem Colaborativa com *Pearson R*. Essas recomendações correspondem aos filmes não avaliados pelo usuário alvo da recomendação na base de dados Teste. Para analisar os resultados, as recomendações são comparadas com as avaliações que o usuário realizou na base de dados Treino, sendo conduzidas análises de precisão e cobertura.

#### 6.2.3.1.2 Resultados

Ao aplicar a metodologia descrita, foram geradas 15768 recomendações de 880 filmes para 213 usuários, recomendando uma média de 74,03 filmes por usuário.

É importante notar que 213 usuários representam 46% da base de dados Teste, com isso, 54% não receberam nenhuma recomendação pela Filtragem Colaborativa tradicional, isso se deve pelo fato dos usuários não poderem ser correlacionados com outros usuários por não possuírem avaliações para os mesmos filmes o suficiente.

Quando verificada a quantidade média de avaliações feitas pelos usuários, os usuários que receberam recomendações avaliaram em média 77,29 filmes, já os que não receberam recomendações avaliaram em média 14,20 filmes, evidenciando o problema do novo usuário.

Outro fator importante é que dos 1410 Filmes da base de dados, 880 foram recomendados pela Filtragem Colaborativa tradicional, representando 62% da base de dados, isso

evidencia o problema do novo item, onde 38% dos itens não foram recomendados por não possuírem uma grande quantidade de avaliadores.

Quando verificado a quantidade média de avaliações que os filmes receberam, os filmes que foram recomendados receberam uma média de 21,15 avaliações, já os filmes que não foram recomendados, receberam em média 2,41 avaliações. O erro médio absoluto das avaliações foi  $MAE=0,75$ .

Com o teste de hipóteses Z pela comparação de médias com a variância conhecida, as hipóteses estabelecidas foram:

$H_0: \mu_1 = \mu_2$ , a média das avaliações preditas é igual à média das avaliações reais

$H_1: \mu_1 \neq \mu_2$ , a média das avaliações preditas é diferente da média das avaliações reais

Para o teste bilateral acima, foram consideradas as seguintes variáveis:

- $n = n_1 = n_2 = 10238$ , sendo uma amostra aleatória das avaliações.
- $X_1$ , amostra das avaliações preditas pelo método da Filtragem Colaborativa na base Teste, com a média  $\bar{X}_1 = 3,66$ ,  $E(X_1) = \mu_1$  e  $V(X_1) = \sigma_1^2 = 0,76$ .
- $X_2$ , amostra das avaliações reais na base Treino, com a média  $\bar{X}_2 = 3,64$ ,  $E(X_2) = \mu_2$  e  $V(X_2) = \sigma_2^2 = 1,08$ .

Com isso, foi calculado o valor de Z, conforme a Equação 6 (Seção 6.1.1.3). Ao nível de significância de 95% o intervalo de confiança está compreendido em  $-1,96 \leq Z_{\mu_1 - \mu_2} \leq 1,96$ , como obteve-se  $Z_{\mu_1 - \mu_2} = 1,31$ ,  $H_0$  ficou dentro do intervalo de confiança. Com isso, não existem evidências para rejeitar a hipótese  $H_0$  de que a média das avaliações preditas pela Filtragem Colaborativa é igual a média das avaliações feitas pelos usuários ao nível de significância de 95%.

**Tabela 9: Teste de hipóteses Z para comparação de médias pelo método da Filtragem Colaborativa.**

Teste-z: duas amostras para médias	Predições	Valores Reais
Média	3,66	3,64
Variância conhecida	0,76	1,08
Observações	10238	10238
Hipótese da diferença de média	0	
Z	1,31	
P(Z<=z) bilateral	0,19	
z crítico bilateral	1,96	

A Tabela 10 apresenta sinteticamente os resultados obtidos com os testes realizados para a Filtragem Colaborativa tradicional.

**Tabela 10: Resultados de cobertura e precisão da Filtragem Colaborativa tradicional.**

Cobertura				Diferença de médias	
Filmes	%Filmes	Usuários	%Usuários	MAE	Teste de Hipóteses Z
880	62%	213	46%	0,75	1,31

### 6.2.3.2 Experimento 2: Redes de confiança direta (*Pearson*)

No modelo proposto, podemos trabalhar com duas opções: a primeira parte-se de uma Rede de Confiança fornecida pela comunidade virtual, através da indicação explícita do usuário; a segunda opção, a Rede de Confiança é construída implicitamente pelo sistema conforme descrito na Seção 4.2.1. Nesse experimento será utilizada a segunda opção por não haver indicações de confiança explícitas dos usuários.

Visando a ampliação da recomendação tradicional é adicionada a Rede de Confiança do usuário no cálculo da predição de itens recomendados, através de três passos:

1. É gerada implicitamente a Rede de Confiança direta do usuário, sendo estabelecido seu nível de confiança para outros usuários;
2. A partir da rede direta, pode-se propagar a confiança e ampliar a rede inserindo-se a confiança propagada;
3. O nível de confiança é aplicado nas avaliações dos itens, para que esses itens possam ser inseridos na recomendação final.

### 6.2.3.2.1 Método de pesquisa

Nesse experimento os seguintes passos foram desenvolvidos:

1. Encontrar a confiança direta implícita entre os usuários da base de dados, utilizando a correlação de *Pearson* com algumas características;
2. Ajustar a confiança para o fatores determinados;
3. Calcular as recomendações.

Na base de dados teste do *MovieLens*, não existe a indicação explícita de confiança entre os usuários, sendo assim, para viabilizar nosso teste, foram inferidas as relações de confiança entre usuários baseado pelas avaliações que os usuários fizeram, e para armazenar os dados foi feita uma adaptação à base de dados inserindo-se uma nova tabela, com a seguinte estrutura:

Rede de confiança
usuario1: int
usuario2: int
fatorConfianca: int
transitividade: int

**Figura 41: Estrutura da tabela de Rede de Confiança. A coluna transitividade representa em qual nível foi calculada a confiança, por exemplo, transitividade igual a 1 representa as confianças diretas do usuário.**

Para encontrar o fator de confiança implícita entre os usuários na base de dados Teste, nesse experimento, foi feito o cálculo de *Pearson*. Porém, foram estabelecidas três estratégias com o objetivo de diferenciar da técnica tradicional de Filtragem Colaborativa, descritas a seguir:

1. A correlação de *Pearson* mínima considerada entre os usuários foi de 0,4;
2. Cada usuário poderia ter no máximo 10 indivíduos em sua Rede de Confiança direta, sendo selecionados os indivíduos com maior correlação.

Após isso, os valores de similaridade foram ajustados para adequar ao modelo, conforme Tabela 11. Cabe ressaltar que os valores do ajuste foram decididos durante o processo da pesquisa para melhor representar os valores encontrados pela similaridade.

**Tabela 11: Ajuste da correlação de *Pearson* para os fatores de confiança.**

<i>Pearson</i>	Fator ajustado
0,40 a 0,49	0,2
0,50 a 0,59	0,4
0,60 a 0,69	0,6
0,70 a 0,79	0,8
0,80 a 0,89	0,9
0,90 a 1,00	1,0

Com isso, a distribuição dos usuários com pessoas confiáveis na base de dados ficou conforme a Figura 42. Além disso, é importante citar que ao utilizar os critérios acima, a confiança entre os usuários ficou com as propriedades de confiança estipuladas para o modelo, sendo:

- Subjetiva, pois dois usuários possuem confianças diferentes para um indivíduo específico;
- Contextualizada, na medida em que se trata de avaliações de filmes;
- Com possibilidade de ser transitiva, através de métricas de confiança;

Depois de encontrado o nível de confiança entre os usuários, foi possível prever as avaliações e encontrar os itens recomendados, como proposto no modelo, para isso, foi utilizado a Equação 4, detalhada na Seção 4.2.2.3.

$$P_{a,i} = \frac{\sum_{u=0}^n (C_{a,u} * r_{u,i})}{\sum_{u=0}^n C_{a,u}}$$

**Equação 4: Predição de avaliação pela confiança.**

A seguir são apresentados os resultados das recomendações geradas pela Rede de Confiança gerada implicitamente pelo algoritmo *Pearson*.

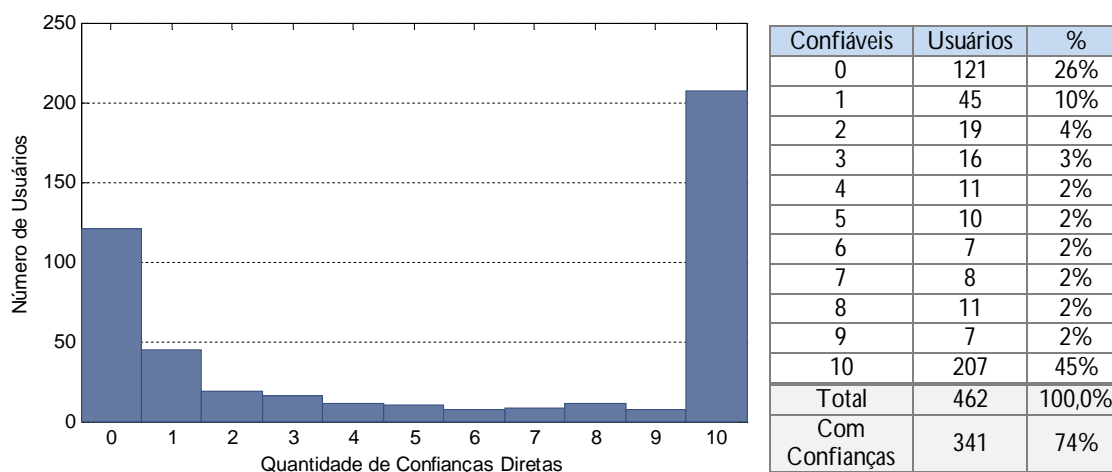
#### 6.2.3.2.2 Resultados

Para esse experimento, foram geradas 18079 recomendações de 990 filmes para 337 usuários, uma média de 53,65 recomendações por usuário. O erro médio absoluto (*MAE*) nesse experimento foi de 0,95.

Quando relacionado à Filtragem Colaborativa tradicional, o método desenvolvido nesse experimento apresentou um maior número de filmes recomendados, isso se deve por não necessitar de um mínimo de avaliações sobre um item para que ele possa ser recomendado, então, filmes que tenham sido avaliados apenas uma vez podem ser recomendados, diminuindo o problema do primeiro avaliador.

É importante destacar que 73% dos usuários receberam recomendações por esse experimento, enquanto na Filtragem Colaborativa tradicional 46% dos usuários haviam recebido recomendações, tal fator se justifica por não haver a necessidade do usuário ter avaliações em comum com outros usuários, pois com apenas uma confiança direta o usuário já pode receber recomendações, diminuindo o problema do novo usuário.

Na tabela anexa da Figura 42 pode-se observar que 74% dos usuários da base de dados têm a possibilidade de receber recomendações, sendo que desse total 29 são representantes do grupo de novos usuários.



**Figura 42: Distribuição de confianças após utilização das características determinadas.**

Com o teste de hipóteses Z pela comparação de médias com a variância conhecida, as hipóteses estabelecidas foram:

, a média das avaliações previstas é igual à média das avaliações reais

, a média das avaliações previstas é diferente da média das avaliações reais



Para o teste bilateral acima, foram consideradas as seguintes variáveis:

- $n = n_1 = n_2 = 3183$ , sendo uma amostra aleatória das avaliações.
- $X_1$ , amostra das avaliações preditas pelo método da Filtragem Colaborativa na base Teste, com a média  $\bar{X}_1 = 3,72$ ,  $E(X_1) = \mu_1$  e  $V(X_1) = \sigma_1^2 = 0,97$ .
- $X_2$ , amostra das avaliações reais na base Treino, com a média  $\bar{X}_2 = 3,73$ ,  $E(X_2) = \mu_2$  e  $V(X_2) = \sigma_2^2 = 1,10$ .

Com isso, foi calculado o valor de Z, conforme a Equação 6 (Seção 6.1.1.3). Ao nível de significância de 95% o intervalo de confiança está compreendido em  $-1,96 \leq Z_{\mu_1 - \mu_2} \leq 1,96$ , como obteve-se  $Z_{\mu_1 - \mu_2} = -0,40$ ,  $H_0$  ficou dentro do intervalo de confiança. Com isso, não existem evidências para rejeitar a hipótese  $H_0$  de que a média das avaliações preditas pela Filtragem Colaborativa é igual à média das avaliações feitas pelos usuários ao nível de significância de 95%.

**Tabela 12: Teste de hipóteses Z para comparação de médias pelo método da Rede de Confiança.**

Teste-z: duas amostras para médias	Avaliação Predita	Avaliação Real
Média	3,72	3,73
Variância conhecida	0,97	1,10
Observações	3183	3183
Hipótese da diferença de média	0	
Z	-0,40	
P(Z <= z) bilateral	0,69	
z crítico bilateral	1,96	

A Tabela 13 apresenta sinteticamente os resultados obtidos com os testes realizados para a Rede de Confiança obtida pela correlação de *Pearson*.

**Tabela 13: Resultados de cobertura e precisão do método da Rede de Confiança por *Pearson*.**

Cobertura				Precisão	
Filmes	%Filmes	Usuários	%Usuários	MAE	Teste de Hipóteses Z
990	70%	337	73%	0,95	-0,4

Como se pode ver, de todos os 341 usuários que poderiam receber recomendações pela Rede de Confiança (*Pearson*), apenas quatro não receberam recomendações, representando 73%

de usuários com recomendações recebidas. Quando comparado com a Filtragem Colaborativa, a Rede de Confiança apresentou um aumento de 37% de usuários com recomendações recebidas, o que representa 124 usuários na base de dados.

Dos 337 usuários que receberam recomendações pela Rede de Confiança, 29 são novos usuários, usuários que fizeram menos de 10 avaliações, enquanto pela Filtragem Colaborativa os 93 usuários novos, conforme Figura 32, não receberam recomendações. Portanto com o método da Rede de Confiança implícita pela correlação de *Pearson* foi possível gerar recomendações diminuindo em 31% o problema do novo usuário.

### 6.2.3.3 Experimento 3: Redes de confiança direta (*Cluster K-means*)


Visando realizar um experimento com uma alternativa ao algoritmo *Pearson*, foi escolhida a técnica de *Cluster K-means* para gerar a Rede de Confiança implícita do usuário e realizar recomendações.

O algoritmo *K-means* funciona com método de particionamento, que organiza os objetos da base de dados em  $k$  partições onde cada partição representa um *cluster* (POE, 1998). O *k-means* é um método que busca os centros de agrupamentos pela minimização direta do critério de erro calculado em função da distância. Como a maioria dos métodos de classificação não-supervisionada, o algoritmo *k-means* necessita da informação *a priori* do número de agrupamentos  $k$  (*k-clusters*; *k-means*).

A partir de uma estimativa inicial (aleatória) das coordenadas dos centros de agrupamento, o algoritmo calcula a distância de cada ponto do conjunto de treinamento às coordenadas das estimativas de centro de agrupamento, de acordo com a função distância *Euclidiana*.

Em seguida, o algoritmo aloca cada registro do conjunto de treinamento em um grupo, de acordo com a menor distância ao centro correspondente. Esta etapa é ilustrada na Figura 43,

abaixo. Os pontos circulares representam os centros de agrupamento e os demais pontos representam os registros.



**Figura 43. Algoritmo *K-Means*. Ilustração dos centros de agrupamento.**

A nova estimativa das coordenadas dos centros de agrupamentos é calculada pela média aritmética das coordenadas dos pontos associados a cada grupo. O algoritmo progride até que os centros dos *clusters* não mudem de uma interação para a próxima.

Assim sendo, a seguir é apresentada a metodologia empregada para o experimento com a técnica *Cluster K-means*.

#### 6.2.3.3.1 Método de pesquisa

Para realizar o Experimento 3, os seguintes passos foram necessários:

1. Aplicar a técnica de *cluster* na base de dados Teste e encontrar os centros dos *clusters*;
2. Encontrar a proximidade entre os usuários através da distância euclidiana entre usuários do mesmo *cluster*;
3. Utilizar essa proximidade como fator de confiança entre os usuários e filtrar as confianças eliminando menores que 0,5;
4. Gerar e analisar as recomendações utilizando o fator de confiança encontrado.


Para encontrar os centros dos *clusters* foi utilizado o programa estatístico SPSS<sup>5</sup>. O aplicativo foi executado para que formasse 10 "*clusters*" (grupos), na base de dados Teste em 20 tentativas.

---

<sup>5</sup> SPSS - *Statistical Package for the Social Sciences* - pacote estatístico para as ciências sociais.

Foram escolhidos 10 *clusters*, pois foi onde se encontrou grupos mais homogêneos dos usuários, ficando com a distribuição conforme a Tabela 14.

**Tabela 14: Distribuição de usuários por *Cluster*.**



**Figura 44: Distribuição dos usuários por *Cluster*, onde os círculos representam os usuários.**

Para cálculo da confiança direta implícita entre um usuário e outro, foi criada a Equação 7 entre usuários do mesmo *cluster*, essa equação, criada pelo autor, foi decisiva para encolha dos usuários que fariam parte da rede de confiança.

**Equação 7: Confiança implícita pelo método da Cluster.**

Onde,  $c_{ab}$  é a confiança do usuário  $a$  para o usuário  $b$ ,  $d_a$  é a distância do usuário  $a$  para o centro do *cluster* que pertence,  $d_{max}$  e  $d_{min}$  são as distâncias máxima e mínima de todos os usuários do mesmo *cluster* para o centro do *cluster*. Quando aplicada essa equação fica garantido quanto mais próximo dois usuários estiverem do centro do *cluster* que pertencem, maior será a confiança entre eles.

Após encontrar as confianças pela Equação 7, foi estabelecido um filtro para refinar as confianças encontradas por decisão da pesquisa, nesse filtro a tabela de confianças foi reduzida descartando-se todas as confianças menores que 0,5, conforme a Tabela 15.

**Tabela 15: Exemplo da tabela de confiança entre usuários pelo *cluster K-means*.**

Usuário	Confiança	Nível
1	2	0,96
1	3	0,93
2	3	0,96
2	4	0,57
5	1	0,84
...	...	...

O total de confianças encontradas para cada *cluster* pode ser visto na Tabela 16. É importante notar que de todas as 462 pessoas da base Teste, apenas 9 não tiveram confianças diretas estabelecidas com as estratégias adotadas para esse método. Com isso, 453 pessoas podem receber recomendações, representando 98% dos usuários da base Teste.

**Tabela 16: Total de confianças por *cluster*.**


<i>Cluster</i>	Usuários	Total de Confianças	Usuários com Confiança
1	12	57	10
2	7	14	6
3	38	165	37
4	73	755	72
5	155	3191	155
6	149	3564	148
7	1	0	0
8	1	0	0
9	1	0	0
10	25	266	25
	462	8012	453

Nesse experimento, as confianças foram calculadas somente para usuários do mesmo grupo, porém, como pode ser visto na Tabela 17, sabe-se a distância entre os centros dos grupos, com isso é possível calcular a distância entre usuários de grupos diferentes.

**Tabela 17: Distâncias entre centro dos *clusters*.**

<i>Cluster</i>	1	2	3	4	5	6	7	8	9	10
1		19,69	14,13	15,80	19,57	20,03	53,89	50,33	50,91	15,99
2	19,69		15,92	17,82	19,03	19,72	56,00	51,20	52,52	19,00
3	14,13	15,92		9,16	11,71	12,45	53,17	50,48	50,55	12,65
4	15,80	17,82	9,16		10,20	10,28	52,86	51,85	50,56	12,20
5	19,57	19,03	11,71	10,20		3,75	56,60	54,59	53,18	17,82
6	20,03	19,72	12,45	10,28	3,75		56,79	54,69	53,05	18,05
7	53,89	56,00	53,17	52,86	56,60	56,79		69,71	68,08	52,17
8	50,33	51,20	50,48	51,85	54,59	54,69	69,71		66,74	50,89
9	50,91	52,52	50,55	50,56	53,18	53,05	68,08	66,74		49,32
10	15,99	19,00	12,65	12,20	17,82	18,05	52,17	50,89	49,32	

A Figura 45 mostra a distribuição dos usuários em relação às suas distâncias ao centro do *Cluster* que pertence.



**Figura 45: Representação *Box-plot* das distâncias dos usuários para o centro do *cluster* que ele pertence.**

Conhecendo a Rede de Confiança do usuário é possível calcular a predição dos itens para ele, para isso, utilizou-se a Equação 4 detalhada na Seção 4.2.2.3.

---

#### **Equação 4: Predição de avaliação pela confiança.**

Nesse estudo não foi realizada a propagação da confiança, porém, conhecendo as confianças diretas do usuário, é possível encontrar a propagação através da Equação 3, detalhada na Seção 4.2.2.2.

A seguir são apresentados os resultados da aplicação desse experimento, com a Rede de Confiança implícita gerada pela técnica *Cluster K-means*.

#### 6.2.3.3.2 Resultados

Depois de aplicado o método desse experimento, foram geradas 20188 recomendações de 1097 filmes para 445 usuários, uma média de 45,37 recomendações por usuário, com erro médio absoluto das avaliações de  $MAE=0,94$ .

Outro dado a se observar nas execuções do *K-means* é a quantidade de elementos por grupo. Conforme mostra a tabela 3, não existe um valor padrão para o tamanho dos grupos. A alocação dos usuários em cada grupo depende apenas da "similaridade" das suas avaliações em cada item.

Com o teste de hipóteses Z pela comparação de médias com a variância conhecida, as hipóteses estabelecidas foram:

$H_0: \mu_1 = \mu_2$ , a média das avaliações preditas é igual à média das avaliações reais

$H_1: \mu_1 \neq \mu_2$ , a média das avaliações preditas é diferente da média das avaliações reais

Para o teste bilateral acima, foram consideradas as seguintes variáveis:

- $n = n_1 = n_2 = 2092$ , sendo uma amostra aleatória das avaliações.
- $X_1$ , amostra das avaliações preditas pelo método da Filtragem Colaborativa na base Teste, com a média  $\bar{X}_1 = 3,63$ ,  $E(X_1) = \mu_1$  e  $V(X_1) = \sigma_1^2 = 0,68$ .
- $X_2$ , amostra das avaliações reais na base Treino, com a média  $\bar{X}_2 = 3,63$ ,  $E(X_2) = \mu_2$  e  $V(X_2) = \sigma_2^2 = 1,27$ .

Com isso, foi calculado o valor de Z, conforme a Equação 6 (Seção 6.1.1.3). Ao nível de significância de 95% o intervalo de confiança está compreendido em  $-1,96 \leq Z_{\mu_1 - \mu_2} \leq 1,96$ , como obteve-se  $Z_{\mu_1 - \mu_2} = 0,19$ ,  $H_0$  ficou dentro do intervalo de confiança. Com isso, não existem evidências para rejeitar a hipótese  $H_0$  de que a média das avaliações preditas pela Filtragem Colaborativa é igual à média das avaliações feitas pelos usuários ao nível de significância de 95%.

**Tabela 18: Teste de hipóteses Z para comparação de médias pelo método do Cluster.**

Teste-z: duas amostras para médias	Predições	Valores Reais
Média	3,63	3,63
Variância conhecida	0,68	1,27
Amostra	2092	2092
Hipótese da diferença de média	0	
Z	0,19	
P(Z <= z) bilateral	0,85	
z crítico bilateral	1,96	

Dos 464 usuários da base de dados, 445 receberam recomendações, apresentando uma cobertura de 96% dos usuários da base de dados com recomendações. A Tabela 19 apresenta sinteticamente os resultados obtidos com os testes realizados para a Rede de Confiança obtida pelo método de *Cluster K-means*.

**Tabela 19: Resultados de cobertura e precisão do método da Rede de Confiança por *Cluster K-means*.**

Cobertura				Precisão	
Filmes	%Filmes	Usuários	%Usuários	MAE	Teste de Hipóteses Z
1097	78%	445	96%	0,94	0,19

Dos 445 usuários que receberam recomendações pela Rede de Confiança, 79 são novos usuários, usuários que fizeram menos de 10 avaliações, enquanto pela Filtragem Colaborativa os 93 usuários novos, conforme Figura 32, não receberam recomendações. Portanto com o método da Rede de Confiança implícita pelo *Cluster K-means* foi possível gerar recomendações diminuindo em 82% o problema do novo usuário.

A seguir são comparados os resultados obtidos pelos 3 experimentos conduzidos, acompanhados das conclusões para o Estudo 1.

#### 6.2.4 Conclusões do Estudo 1

A hipótese desse trabalho é: “Utilizando a confiança do usuário, é possível gerar recomendações mais confiáveis e fazer com que novos usuários comecem a receber recomendações mais rapidamente”.

Com o objetivo de mostrar evidências que comprovam a hipótese dessa pesquisa, na Tabela 20 são apresentados os resultados dos três experimentos quando aplicados aos novos usuários da base de dados. Nessa tabela pode-se ver que aplicando a técnica tradicional de filtragem colaborativa, nenhum novo usuário teve a possibilidade de receber recomendações, no entanto, quando aplicado o método da Rede de Confiança do usuário, as duas técnicas



desenvolvidas conseguiram recomendar itens para os novos usuários, diminuindo o problema do novo usuário, comprovando a hipótese dessa dissertação.

**Tabela 20: Quadro comparativo da cobertura de usuários que receberam recomendações pelas três técnicas.**

	Recomendações Feitas						
	Total	Filtragem Colaborativa	%FC	Rede de Confiança (Pearson)	%RC (Pearson)	Rede de Confiança (Cluster)	%RC (Cluster)
Usuários	462	213	46%	337	73%	445	96%
Novos usuários	93	0	0%	29	31%	76	82%

Para apresentar resultados quanto à qualidade das recomendações, na Tabela 21 pode-se ver que pelo teste de erro médio *MAE*, a Filtragem Colaborativa tradicional apresentou um resultado melhor que as técnicas pela Rede de Confiança, porém quando aplicado o teste de hipótese Z, a técnica de Rede de Confiança pelo *Cluster* apresentou o melhor resultado por estar mais próximo de zero, já que a hipótese nula desse trabalho é que a média das recomendações preditas para o usuário é igual a média das avaliações reais dele.

Com isso, as duas técnicas utilizando a Rede de Confiança apresentaram uma qualidade melhor nas recomendações pelo teste de hipóteses Z quando comparados com a Filtragem Colaborativa tradicional, comprovando a hipótese dessa dissertação.

**Tabela 21: Quadro comparativo das três técnicas experimentadas quanto aos testes de cobertura, precisão *MAE* e teste de hipóteses Z.**

Técnica utilizada	Cobertura				Precisão	Diferença de médias
	Filmes	%Filmes	Usuários	%Usuários	<i>MAE</i>	Teste de Hipótese Z
Filtragem Colaborativa	880	62%	213	46%	0,75	1,31
Rede de Confiança (Pearson)	990	70%	337	73%	0,95	-0,40
Rede de Confiança (Cluster)	1097	78%	445	96%	0,94	0,19

Novos usuários são os mais beneficiados com a utilização da Rede de Confiança, já que, com a indicação de apenas uma pessoa para sua Rede de Confiança, ele já pode começar a receber recomendações. Este pode ser um mecanismo para integrar mais rapidamente novos usuários na comunidade virtual, principalmente quando comparado com a Filtragem

Colaborativa, onde os novos usuários devem avaliar pelo menos 10 itens para que possam começar a receber recomendações.

Em comunidades virtuais, é normal que os usuários avaliem uma pequena quantidade de itens do total existente, causando uma grande porcentagem de células vazias. Na Filtragem Colaborativa, apenas itens avaliados por duas ou mais pessoas são considerados no cálculo de similaridade. Porém ao utilizar a Rede de Confiança, existem evidências de minimizar o problema da matriz esparsa, já que, ao propagar a confiança do usuário, os itens podem ser recomendados a partir do nível de confiança estabelecido entre usuários, independente do usuário alvo da recomendação possuir ou não itens avaliados em comum com o usuário da propagação.

Enfim, os três experimentos do Estudo 1 foram de extrema importância para validação do modelo proposto, uma vez que permitiram:

1. Verificar o funcionamento do modelo em uma comunidade virtual com muitos dados históricos;
2. Auxiliar na correta instanciação do modelo de recomendação com redes de confiança para sua aplicação no ActivUFRJ;
3. Verificar a possibilidade de gerar implicitamente a Rede de Confiança do usuário;
4. Verificar que a aplicação do modelo com duas técnicas distintas para geração da Rede de Confiança implícita do usuário mostrando a flexibilidade do modelo, viabilizando sua aplicação com outras técnicas de recomendação;
5. Verificar que o modelo minimizou o problema comum da Filtragem Colaborativa com novos usuários da comunidade;
6. Verificar se as recomendações produzidas pelas confianças do usuário tiveram melhor qualidade do que as recomendações produzidas pela Filtragem Colaborativa.

### 6.2.5 Limitações dos experimentos

Nestes experimentos realizados foram percebidas algumas limitações. Uma das limitações percebidas refere-se aos experimentos terem sido realizados com uma amostra não-probabilística o que torna os resultados interessantes, porém não generalizáveis.

A base de dados escolhida constituiu-se em outra limitação, pois todos os dados são relativos a filmes, sendo difícil generalizar para outras áreas de interesse. Além disso, outra limitação da base de dados está no fato de não possuir dados relativos à confiança do usuário em outros da comunidade, sendo necessário gerar a Rede de Confiança implícita do usuário. Outros modelos, utilizando sistemas de reputação (CRUZ *et al.*, 2007) ou a indicação explícita do usuário devem ser analisados no sentido de construir a Rede de Confiança e melhorar a qualidade das recomendações.

## 6.3 Estudo 2: O Protótipo ActivUFRJ

A fim de validar a solução proposta diante dos objetivos da pesquisa foi agregado o protótipo dentro da comunidade virtual ActivUFRJ (Seção 4.5) com alunos, professores e funcionários da UFRJ. Para tal, foi planejada a execução de uma atividade envolvendo avaliação de filmes com vistas a capturar informações para a análise dos resultados, relacionadas com os seguintes objetivos:

- Avaliar a quantidade de participação dos usuários mediante medidas quantitativas e qualitativas;
- Validar o modelo, sua confiabilidade e representatividade;
- Observar o uso da ferramenta e programar as correções necessárias;
- Registrar as impressões dos participantes em questionário e por suas considerações.

### 6.3.1 Detalhamento do estudo de caso

Para realização do experimento, foi necessária a implementação de algumas ferramentas no ActivUFRJ, entre elas: avaliação de artefatos, redes de confiança e recomendações, que estão detalhados na Seção 5.3.

Foi criada, dentro do ambiente, uma comunidade chamada “Filmes” com os 100 filmes de maior bilheteria da história, mas sendo permitido aos usuários inserirem filmes se desejassem. Cada filme foi inserido com seu Pôster e com uma pequena descrição.

Para que não houvesse uma super-especialização das avaliações (poucos filmes com avaliação), os filmes eram exibidos aleatoriamente aos participantes, portanto a comunidade filmes não possuía uma ordem definida dos filmes, a cada nova entrada na comunidade a ordem apresentada era diferente.

Cerca de 30 pessoas foram convidadas por e-mail, e dessas, 19 participaram voluntariamente do experimento. Com relação à profissão exercida, 80% são estudantes de pós-graduação, 16% são professores e 4% são funcionários da Universidade. Ressalta-se que os e-mails dos convidados foram retirados de listas de estudantes de pós-graduação e de conhecidos do Programa de Pós-Graduação em Informática da UFRJ.

### 6.3.2 Organização do estudo

Inicialmente, foi enviado um *e-mail* para alguns amigos, professores e funcionários que tinham alguma relação com a UFRJ, solicitando a participação no experimento, o *e-mail* pode ser visto no Anexo B.

O estudo de caso foi realizado entre os meses de março e abril de 2008. Sendo dividido em cinco etapas semanais, cada uma possuindo um objetivo, sendo solicitado aos usuários a fazer as seguintes ações:

1. *Ambientação*: entrar no ambiente, realizar o cadastro e navegar livremente para conhecer melhor as funcionalidades.
2. *Avaliação*: avaliar entre 20 e 40 filmes da comunidade filmes, sendo o mais honesto possível. Estas avaliações servem para montar o perfil do usuário e, a partir dele, recomendar filmes para ele.
3. *Rede de Confiança*: Inserir pelo menos 2 pessoas na Rede de Confiança.
4. *Feedback das recomendações pela Filtragem Colaborativa*: concordar ou não com as predições realizadas pelo método da Filtragem Colaborativa.
5. *Feedback das recomendações pela Rede de Confiança*: concordar ou não com as predições realizadas pelo método da Rede de Confiança.

Após essas etapas foi aplicado um questionário com o objetivo de verificar a opinião dos usuários sobre a utilização do ambiente. As perguntas foram relacionadas aos recursos tecnológicos utilizados, funcionalidades e interface do ambiente, avaliação de artefatos, Rede de Confiança e recomendações recebidas. O questionário encontra-se no Anexo C dessa pesquisa com as respostas dos usuários representadas em gráficos de barras.


Todas as etapas do experimento foram importantes na coleta de dados. Em cada uma, foram adotadas estratégias diferentes, estas estratégias estão descritas a seguir.

### **6.3.3 Coleta de dados**

Na etapa 1, foram armazenadas informações referentes ao que o usuário fez durante a navegação no ambiente. Tais informações podem ser usadas em trabalhos futuros para formar os perfis de usuários. Entre as informações coletadas estão: acesso aos artefatos, visitas às páginas de outros usuários, criação de artefatos, criação de comunidades, buscas realizadas, etc.

Na etapa 2, os usuários avaliaram os filmes livremente, com o objetivo de haver muitas avaliações sobre os filmes, foi solicitado aos usuários para avaliarem entre 20 e 40 filmes, porém

nem todos ficaram dentro desta média. No total foram feitas 379 avaliações de filmes por 19 usuários, sendo que dois usuários fizeram apenas 1 avaliação e o usuário com mais avaliações fez 49 avaliações, a distribuição completa de avaliações pode ser vista na Figura 46. A média de avaliações por usuário foi de 19,90. Um usuário não avaliou nenhum filme.



**Figura 46: Distribuição de avaliações dos participantes.**

A distribuição da quantidade de avaliações para os filmes pode ser vista na Tabela 22.

**Tabela 22: Distribuição dos filmes pela quantidade de avaliações recebidas.**

Quantidade de Avaliações	Número de Filmes	% de Avaliações
1	19	5%
2	18	10%
3	18	14%
4	11	12%
5	13	17%
6	10	16%
7	6	11%
8	3	6%
9	1	2%
12	1	3%
13	1	3%
	101	100%

Como foi permitido ao usuário adicionar outros filmes além da lista, 4 filmes foram adicionados, portanto a quantidade de filmes na comunidade passou a ser 104. Desse total, 101 filmes receberam avaliações. A média de avaliações por filme foi de 3,64. A Figura 47 apresenta a distribuição das avaliações feitas para os filmes.

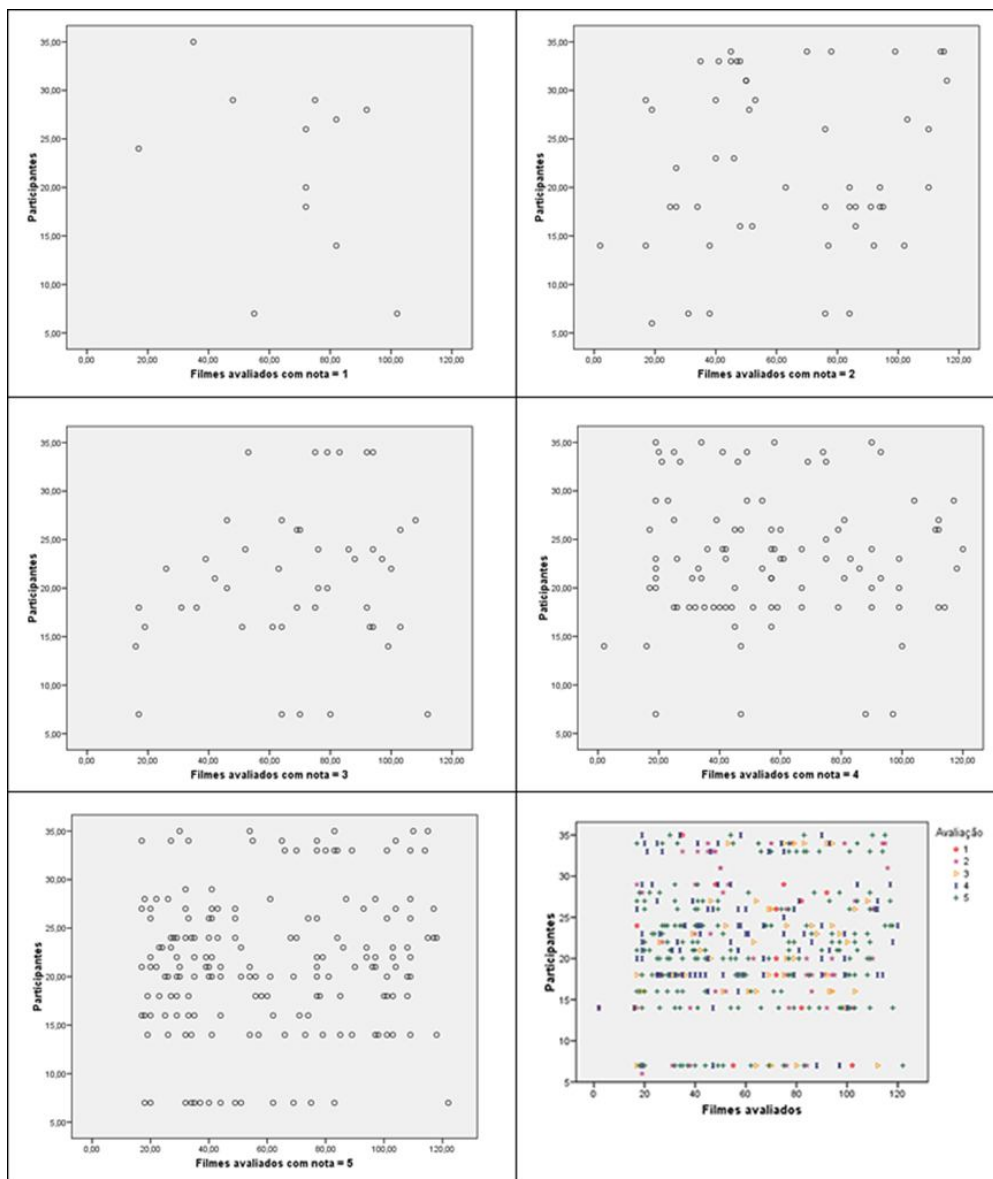



Figura 47: Distribuição de avaliações feitas pelos participantes para os filmes do experimento.

A distribuição de notas dadas para os filmes são apresentadas na Tabela 23.

Tabela 23: Distribuição de avaliações pela quantidade de estrelas que foi avaliado.



Estrelas	Número de Avaliações	%
5	173	46%
4	95	25%
3	46	12%
2	52	14%
1	12	3%
	379	100%

Na etapa 3, foi solicitado aos participantes colocarem 2 pessoas em sua Rede de Confiança. Para isso, o participante tinha que acessar a página de outro usuário e dentro da página do usuário era possível ver todas as avaliações que o usuário tinha feito, e com isso o participante poderia decidir inserir ou não o usuário na sua Rede de Confiança. No total foram indicadas 50 confianças diretas para a área de interesse “filmes” por 14 participantes. O participante que indicou o maior número de pessoas para sua Rede de Confiança fez 16 indicações e o menor fez 1 indicação, como se pode ver na Tabela 24.

**Tabela 24: Distribuição de confianças diretas de todos os usuários.**

Confianças Feitas	Total de Usuários	Total de Confianças	% de Usuários
1	1	1	7%
2	5	10	36%
3	3	9	21%
4	3	12	21%
5	1	5	7%
16	1	16	7%
	14	49	100%

A Tabela 25 mostra que 3 usuários foram confiados por apenas 1 usuário, por outro lado 2 usuários foram confiados por 8 usuários. No total 16 usuários foram confiados de todos os 19 participantes.

**Tabela 25: Distribuição de confianças recebidas pelos usuários.**

Confianças Recebidas	Total de Usuários
1	3
2	5
3	4
4	1
5	1
8	2
Total	16

Também é interessante notar o nível de confiança indicados pelos usuários, conforme a Tabela 26, pode-se ver que a maioria dos usuários indicou o nível 3 (Alto) de confiança e nenhum usuário estabeleceu o nível 0 (Nada).



**Tabela 26: Distribuição dos níveis de confiança realizados pelos usuários.**

Nível da Confiança	Número de Confianças	% das confianças
0	0	0%
1	4	8%
2	24	45%
3	25	47%
Total	53	100%

Cabe ressaltar que as indicações de confiança 0 e 1 foram utilizadas como filtro das recomendações geradas para o participante pela Rede de Confiança, esse filtro se deu pela eliminação de todas as predições que tivessem sido exatamente iguais às avaliações dos usuários que receberam as indicações de confiança 0 ou 1 pelo participante.

As etapas 4 e 5 foram unidas em uma etapa. Nesse momento o usuário deveria concordar ou não com as predições recomendadas pelo método de Filtragem Colaborativa e pelo método de redes de confiança, essa concordância serviu como *feedback* dos usuários para as avaliações recebidas. Nessa etapa dois usuários não deram *feedback* para as recomendações. De todas as 660 recomendações 391 foram avaliadas pelos usuários. O retorno do usuário foi importante para verificarmos a qualidade das recomendações pelos testes de precisão e teste de hipóteses Z.

Após a conclusão das etapas, os usuários responderam um questionário. O questionário também teve grande importância, pois com ele foi possível obter dados de satisfação dos participantes e avaliar o ambiente como um todo.

A seguir, é apresentada a análise dos resultados do experimento no ActivUFRJ.

### 6.3.4 Resultados

Na Tabela 27 são apresentados os resultados da análise das recomendações separadamente para cada participante do experimento. Cabe ressaltar que as avaliações dessa tabela foram feitas com base nas análises do *feedback* dos usuários sobre as recomendações

recebidas. Assim sendo, nossa Hipótese nula  $H_0: \mu_1 = \mu_2$  é que a média das avaliações previstas para o participante é igual à média das avaliações reais dele, sendo que as avaliações reais são o *feedback* do participante.

**Tabela 27: Resultados e dados gerais do experimento no ActivUFRJ.**

Participante	Avaliações Realizadas	Confianças Diretas	Confianças Recebidas	Recomendações geradas			Avaliação		
				Filtragem Colaborativa	Rede de Confiança	<i>Feedback</i>	Precisão <sup>6</sup>	<i>MAE</i>	Teste de Hipótese Z
6	1					-	-	-	-
7	30	5	8	26	40	40	53%	0,70	-0,68
14	31	3	8	27	13	22	59%	0,55	-2,43
16	23	4	5	31	21	40	55%	0,75	-0,21
18	49	3	2	12	7	18	61%	0,44	0,00
20	32	2	3	20	11	18	72%	0,61	1,30
21	21	4	3	29	17		49%	0,70	1,26
22	20		1	27		-	-	-	-
23	21	1	2	6	15	6	17%	1,17	-1,94
24	28	2	3	26	19	16	75%	0,38	-0,46
25	1	2			9	5	80%	0,20	-0,28
26	23	4	2	27	15	2	0%	1,50	-3,00
27	18	2	4	29	26	61	54%	0,95	1,17
28	10		2	28		24	58%	0,71	-2,11
29	13	2	1	35	13	22	41%	0,91	1,03
31	3		2	5		5	60%	0,60	-1,90
34	21		1	27		21	62%	0,57	1,67
35	25		3	22		20	60%	0,60	0,80
36		16			76	71	37%	1,07	0,44
Total	379	50	50	377	283	391	53%	0,77	-0,18

É importante notar que o *Participante 18*, com 49 avaliações, recebeu 19 recomendações de filmes e o *Participante 36*, com 0 avaliações e 16 indicações de confiança, recebeu 76 recomendações de filmes. Essa diferença na quantidade de recomendações recebidas pode ser justificada por dois motivos:


<sup>6</sup> A métrica “Precisão” foi inserida nesse estudo, sendo considerada como a porcentagem de recomendações feitas exatamente igual ao que o participante avaliou.

1. O método da Rede de Confiança não precisa encontrar similaridade entre os participantes pelas avaliações feitas por eles, ele utiliza as avaliações feitas pelos indivíduos da Rede de Confiança para gerar recomendações;
2. A comunidade possui um total de 104 filmes cadastrados, como o *Participante 18* avaliou 48 filmes, o total de filmes que podem ser recomendados para ele é de 56 filmes, já o *Participante 36* não fez nenhuma avaliação, com isso o total de filmes que podem ser recomendados para ele é de 104 filmes.

Para os participantes 14, 26 e 28, o teste de hipóteses  $Z$  apresentou que ao nível de significância de 5%, a hipótese nula  $H_0: \mu_1 = \mu_2$ , deve ser rejeitada, indicando que não é possível afirmar que a média das avaliações preditas para o participante é igual à média avaliada por ele.

Ao analisar os três participantes, pôde-se observar que:

1. O Participante 26 a amostra considerada foi de apenas 2 avaliações, podendo ter sido o fator de interferência do teste.
2. Para os Participantes 14 e 28, não se pode afirmar que o erro tenha sido causado pelas recomendações com a Filtragem Colaborativa ou com a Rede de Confiança. Porém quando verificada a forma de avaliar dos dois participantes, representada na Figura 48, é possível ver que eles apresentaram a mesma forma de avaliar, sendo diferentes dos demais participantes, com avaliações compreendendo todas as notas e a mediana das avaliações na nota 5. Em trabalhos futuros, mais estudos devem ser feitos com esses perfis de usuários, para verificar se a ocorrência dessas distorções foi um caso isolado ou se, para usuários com esse perfil, deve ser aplicada uma técnica de recomendação diferenciada, para que o erro seja corrigido.



**Figura 48: Box-Plot** representando a forma de avaliar dos Participantes.

Pela Filtragem Colaborativa foram geradas 377 recomendações para 16 usuários, recomendando uma média de 23,56 filmes por usuário. É importante notar que nessa técnica, 45 filmes foram recomendados aos usuários, representando 43% do total de filmes.

Apesar da técnica de Filtragem Colaborativa gerar recomendações para um grupo maior de participantes, atingiu uma menor quantidade de filmes em suas recomendações. Isso ocorreu, pois os filmes não recomendados pela Filtragem Colaborativa, não receberam uma quantidade suficiente de avaliações. Quando verificado a quantidade média de avaliações que os filmes receberam, os filmes que foram recomendados pela Filtragem Colaborativa receberam uma média de 5,84 avaliações, já os filmes que não foram recomendados, receberam em média 2,04 avaliações, evidenciando o problema do novo item.

Já pela Rede de Confiança foram geradas 283 recomendações para 14 usuários, recomendando uma média de 20,21 filmes por usuário. Essas recomendações cobriram 96 filmes de um total de 104 filmes, representando 92% do total de filmes. Isso mostra que a recomendação pela Rede de Confiança é independente da quantidade de avaliações recebidas pelos filmes, já que a média de avaliações feitas para os filmes recomendados pela Rede de Confiança, foi de 3,89. Quando verificada a quantidade de filmes avaliados pelos usuários que

foram incluídos na Rede de Confiança, verificou-se que eles avaliaram um total de 97 filmes, com isso, apenas 1 filme não foi coberto pelo método da Rede de Confiança.

Além disso, a quantidade de usuários cobertos pela Rede de Confiança atingiu 14 usuários, representando 74% de todos os participantes. Onde todos os usuários que indicaram um participante para sua Rede de Confiança receberam recomendações.

Com isso, a utilização da Rede de Confiança apresentou um resultado melhor na cobertura dos filmes da base de dados, não necessitando de muitas avaliações para que o filme fosse recomendado. Por outro lado, a Filtragem Colaborativa apresentou um resultado melhor na quantidade de pessoas que receberam recomendações.

Quando feita a união das duas técnicas, as limitações apresentadas por cada uma trabalhando separadamente foram reduzidas, onde 93% dos filmes foram recomendados e 95% dos participantes receberam recomendações.

Considerando ainda, os novos usuários como participantes com menos de 10 avaliações, é possível notar que pertencem a esse grupo os Participantes 6, 25, 31 e 36. Desses 4 participantes, apenas o Participante 6 não recebeu recomendações, enquanto os outros 3 receberam recomendações. Contudo, os Participantes 25 e 36 só puderam receber recomendações pela Rede de Confiança. Mostrando evidências que a Rede de Confiança pode minimizar o problema do novo usuário da Filtragem Colaborativa.

Com o teste de hipóteses Z pela comparação de médias com a variância conhecida, as hipóteses estabelecidas foram:

$H_0: \mu_1 = \mu_2$ , a média das avaliações preditas é igual à média das avaliações reais

$H_1: \mu_1 \neq \mu_2$ , a média das avaliações preditas é diferente da média das avaliações reais

Para o teste bilateral acima, foram consideradas as seguintes variáveis:

- $n = n_1 = n_2 = 391$ , sendo uma amostra aleatória das avaliações.

- $X_1$ , amostra das avaliações previstas pelo método da Filtragem Colaborativa na base Teste, com a média  $\bar{X}_1 = 3,82$ ,  $E(X_1) = \mu_1$  e  $V(X_1) = \sigma_1^2 = 0,99$ .
- $X_2$ , amostra das avaliações reais na base Treino, com a média  $\bar{X}_2 = 3,84$ ,  $E(X_2) = \mu_2$  e  $V(X_2) = \sigma_2^2 = 1,06$ .

Com isso, foi calculado o valor de  $Z$ , conforme a Equação 6 (Seção 6.1.1.3). Ao nível de significância de 95% o intervalo de confiança está compreendido em  $-1,96 \leq Z_{\mu_1 - \mu_2} \leq 1,96$ , como obteve-se  $Z_{\mu_1 - \mu_2} = -0,18$ ,  $H_0$  ficou dentro do intervalo de confiança. Com isso, não existem evidências para rejeitar a hipótese  $H_0$  de que a média das avaliações previstas para os participantes é igual à média das avaliações feitas pelos participantes ao nível de significância de 95%, conforme Tabela 28.

**Tabela 28: Teste de hipóteses do experimento com o ActivUFRJ.**

Teste-z: duas amostras para médias	Predições	Valores Reais
Média	3,82	3,84
Variância conhecida	0,99	1,06
Amostra	391	391
Hipótese da diferença de média	0	
$Z$	-0,18	
$P(Z <= z)$ bilateral	0,86	
$z$ crítico bilateral	1,96	

Na Tabela 29 são apresentados os resultados de cobertura e precisão para as técnicas aplicadas nesse experimento.

**Tabela 29: Resultados de cobertura e precisão das técnicas de recomendação empregadas nos experimentos.**

Técnica de Recomendação	Cobertura				Avaliação		
	Filmes	%Filmes	Usuários	%Usuários	Precisão	MAE	Teste de Hipóteses Z
Filtragem Colaborativa	45	43%	16	84%	56%	0,69	-1,70
Rede de Confiança	96	92%	14	74%	35%	0,89	1,47
Filtragem Colaborativa + Rede de Confiança	97	93%	18	95%	53%	0,77	-0,18

Analisando-se as duas técnicas isoladamente, a filtragem colaborativa apresentou um melhor resultado quanto à quantidade de pessoas beneficiadas com recomendação e na qualidade

das recomendações pelos testes de Precisão e erro *MAE*, já a técnica de Rede de Confiança apresentou resultados melhores quanto à quantidade de filmes recomendados e com a avaliação pelo teste de hipóteses Z para diferença de médias. Porém quando as duas técnicas funcionaram em conjunto, reduziu os problemas de cobertura de filmes e usuários, e, além disso, apresentou a melhor qualidade pelo teste de hipóteses Z.

Usuários que não fizeram avaliações de filmes, mas colocaram pessoas na sua Rede de Confiança, conseguiram receber recomendações pela Rede de Confiança, mas não receberam recomendações pela Filtragem Colaborativa.

Os novos itens inseridos na comunidade sofrem problemas na Filtragem Colaborativa na medida em que precisam receber pelo menos 2 avaliações para que consigam ser recomendados a outros usuários. Já pelo método da Rede de Confiança, houve itens recomendados aos participantes com apenas uma avaliação.

### 6.3.5 Limitações do modelo

Apesar de o modelo proposto ter apresentado bons resultados referentes à cobertura de filmes e usuários, ele também apresenta algumas limitações, entre elas:

- Para gerar recomendações pela Rede de Confiança, o participante precisa indicar pelo menos um usuário para sua Rede de Confiança e esse usuário indicado tem que ter avaliado pelo menos um item;
- Já pela Filtragem Colaborativa tradicional, devem existir muitas avaliações do filme para que este seja recomendado, além disso, o usuário precisa fazer uma quantidade suficiente de avaliações para que consiga ser correlacionado com outros usuários.

### 6.3.6 Comentários dos participantes

A seguir são apresentados alguns comentários emitidos pelos participantes e considerados relevantes no estudo realizado:

Quando perguntados sobre a funcionalidade do ActivUFRJ como um todo:

1. *"...O ambiente tem que melhorar a usabilidade em alguns aspectos como: - permitir a adição de áreas de interesse e tags pelo usuário, adicionar ferramentas de comunicação, mecanismos de percepção..."*
2. *"...A interface do sistema como um todo necessita ser mais leve, como nos atuais sistemas Web 2.0 ..."*

Quando perguntados sobre a funcionalidade de avaliação de itens:

1. *"...O formulário de avaliação pode apresentar critérios de avaliação específicos de acordo com o tipo de artefato. Se o artefato for filme por exemplo, poderia apresentar os critérios: roteiro, fotografia, figurino, etc. Se for um artigo, poderia ter: originalidade, mérito técnico, relevância, etc. Acho que durante o cadastro do artefato, o usuário poderia optar por usar um formulário genérico (estrelas e comentário) ou um formulário específico onde ele informaria quais critérios ele gostaria que fossem avaliados. Sendo que esse formulário específico precisaria ter a recomendação geral do avaliador para bater o martelo. Algo do tipo: Recomendo/Não Recomendo ou até mesmo as estrelas como avaliação geral..."*

Quando perguntados sobre a funcionalidade de Rede de Confiança:

1. *"...Achei a estrutura do formulário um pouco confusa..."*
2. *"...Quanto à facilidade de encontrar pessoas para adicionar na Rede de Confiança, acho que vai melhorar quando a parte de reputação e combinação social estiver funcionando. Por enquanto, as próprias pessoas observam quem é confiável através das opiniões nas avaliações..."*
3. *"...A facilidade de adicionar pessoas na Rede de Confiança pode ser melhorada. Por exemplo, ao visualizar as avaliações, poderia já existir uma forma de adicionar o avaliador na Rede de Confiança, sem precisar entrar na página de perfil dele. A mesma coisa para remover da Rede de Confiança..."*
4. *"... poderia já existir uma forma de sinalizar que o avaliador já faz parte da sua Rede de Confiança. A estrutura do formulário para adicionar confiança eu não sei ainda se é a ideal. Por enquanto me satisfiz..."*
5. *"... As opções do quanto à pessoa é confiável está associada à confiança geral? Isso não ficou muito claro. A visualização da minha rede está ok..."*

Quando perguntados sobre as recomendações recebidas:



1. "...Não consegui observar se fiquei satisfeita ou não com as recomendações feitas pela Rede de Confiança ou por similaridade porque não deu para perceber o que era recomendado pela Rede de Confiança ou pela similaridade.
2. "... Acho que no geral, concordei com a maioria das recomendações..."

## 6.4 Conclusões

A questão de pesquisa dessa dissertação é: "Como desenvolver um Sistema de Recomendação de itens em uma comunidade para que os problemas relativos à Filtragem Colaborativa sejam minimizados, em especial o problema do novo usuário?"

Para responder essa questão foi elaborada a seguinte hipótese: "Utilizando a confiança do usuário, é possível gerar recomendações mais confiáveis e fazer com que novos usuários comecem a receber recomendações mais rapidamente".

Com isso, foi elaborado um modelo Sistema de Recomendação de itens que utiliza a Rede de Confiança do usuário para gerar as recomendações. Os dois Estudos conduzidos nessa dissertação foram fundamentais para mostrar a viabilidade da hipótese dessa pesquisa. Entre os resultados no que se refere aos novos usuários, têm-se:

1. No Estudo 1 (*off-line*), as duas métricas utilizadas para gerar a Rede de Confiança apresentaram uma maior quantidade de novos usuários do sistema com recomendações, chegando a atingir 82% de aumento com o experimento realizado com a Rede de Confiança gerada pela técnica de *Cluster K-means*.
2. No Estudo 2 (ActivUFRJ), 50% dos novos usuários receberam recomendações pela Rede de Confiança, enquanto pela Filtragem Colaborativa esse índice foi de 25%.

Em relação à qualidade das recomendações, pelo teste de hipóteses Z foi possível verificar que a chance de acerto da Rede de Confiança é maior que da Filtragem Colaborativa. Porém nos dois estudos, as métricas Precisão e *MAE* (no Estudo 1 foi utilizada apenas a métrica *MAE*), apresentaram resultados favoráveis à Filtragem Colaborativa, com isso, trabalhos futuros

devem ser feitos no sentido de fazer os ajustes necessários à técnica de Rede de Confiança visando tornar as recomendações mais confiáveis para o usuário.

Um resultado não esperado, porém muito importante, se refere à quantidade de itens que foram recomendados aos usuários. No Estudo 2, quando aplicada a Rede de Confiança, 92% dos filmes da base de dados foram recomendados aos participantes, enquanto pela Filtragem Colaborativa foram 43% dos filmes. Isso mostra que o modelo também foi eficaz com relação à redução dos outros três problemas da Filtragem Colaborativa: o problema do novo item, o problema da super-especialização e o problema das matrizes esparsas.

- Problema do novo item, pois o item não precisa de muitas avaliações para ser recomendado, para que um item que tenha sido avaliado apenas uma vez possa ser recomendado, é suficiente que o avaliador pertença à Rede de Confiança de outro usuário.
- Problema da super-especialização, pois não são recomendados somente os itens melhores avaliados ou avaliados por mais pessoas, são recomendados itens com relação às pessoas da Rede de Confiança.
- Problema das matrizes esparsas, pois não há necessidade dos usuários possuírem itens avaliados em comum com outros usuários para conseguirem ser correlacionados.

## Capítulo 7

# Considerações Finais e Trabalhos Futuros

---

“O que sabemos é uma gota, o que ignoramos é um oceano.”

*Isaac Newton*

Neste capítulo é apresentado o resumo da pesquisa descrita nessa dissertação, explicitando as suas contribuições, problemas encontrados ao longo do desenvolvimento e sugestões para prosseguimento do trabalho.

## 7.1 Resumo do trabalho

É indiscutível a evolução da tecnologia de informação, principalmente nas duas últimas décadas. Por consequência, a Internet tornou-se uma excelente fonte de consulta de informações. Contudo, na maioria das vezes, os usuários são submetidos a uma sobrecarga de informações, tornando árduo o processo de encontrar informações úteis e confiáveis para a realização de seu trabalho.

No sentido de minimizar a sobrecarga de informações sobre os usuários, surgiram os Sistemas de Recomendação, se apresentando com o potencial de identificar os interesses do usuário para indicar somente as informações relevantes a ele. Porém, com a evolução dos Sistemas de Recomendação, novas questões surgiram principalmente relacionadas à identificação dos interesses do usuário.

Na técnica de recomendação pela Filtragem Colaborativa, essa realidade não é diferente, onde para gerar recomendações, é necessário que se tenha um perfil com as preferências do usuário. Isso afeta principalmente os novos usuários de uma comunidade, que não podem receber recomendações, pois o Sistema de Recomendação não consegue identificar suas preferências.

Com isso, nessa dissertação, é proposto um modelo de Sistemas de Recomendação que utiliza a Filtragem Colaborativa somada com a Rede de Confiança do usuário, com o objetivo de diminuir o problema da Filtragem Colaborativa do novo usuário.

Além de propor um modelo de recomendação que possa ser implementado em um ambiente computacional que apóie comunidades virtuais, foi desenvolvido um protótipo integrado ao ambiente ActivUFRJ. O modelo proposto baseia-se na confiança entre usuários da comunidade, objetivando contribuir na quantidade de pessoas que possam ser beneficiadas com recomendações.

Para avaliar a viabilidade da solução proposta, primeiramente foi realizado o Estudo 1, sem interação de usuários, em dados históricos de uma comunidade de filmes muito utilizada para avaliação de Sistemas de Recomendação (*MovieLens*), na tentativa de validar o modelo proposto e verificar sua eficácia quanto à cobertura e precisão das recomendações. O Estudo 2, envolveu a validação da hipótese da pesquisa com a aplicação do modelo em um protótipo desenvolvido na comunidade virtual *ActivUFRJ*.

Os dois estudos foram aplicados com o objetivo de analisar as contribuições deste Sistema de Recomendação em comparação com o modelo tradicional utilizando a Filtragem Colaborativa, com o algoritmo *Pearson R*. Resultados obtidos foram importantes para mostrar a viabilidade do modelo no que se refere a gerar recomendações aos novos usuários da comunidade, apresentando evidências que validam a hipótese que orienta essa pesquisa.

## 7.2 Contribuições da Dissertação

Uma grande questão em Sistemas de Recomendação refere-se à impossibilidade de gerar recomendações para novos usuários na comunidade, um problema relativo a Sistemas de Recomendação pela Filtragem Colaborativa, onde o usuário precisa avaliar vários itens para começar a receber recomendações.

Nesta dissertação foi apresentado um modelo de recomendação que viabiliza a utilização da Rede de Confiança do usuário para gerar recomendações. Este modelo mostrou-se flexível, funcionando com a Rede de Confiança inferida (sem indicação do usuário) e com a Rede de Confiança criada explicitamente pelo usuário. Através dos resultados dos experimentos realizados, evidenciou-se a relevância da Rede de Confiança no processo de recomendação, sendo que como resultado final verificou-se a diminuição dos problemas relativos à Filtragem Colaborativa, e principalmente, apresentando-se como uma boa solução para o problema do novo usuário.

Com isso, cabe ressaltar as contribuições dessa dissertação, apresentando comentários que elucidam como foram tratados nos experimentos realizados.

- O emprego da confiança do usuário como fator importante para gerar recomendações;
- A possibilidade de integração mais rápida de novos usuários na comunidade, um problema relativo a Sistemas de Recomendação pela Filtragem Colaborativa, onde o usuário precisa avaliar vários itens para começar a receber recomendações. Este trabalho apresenta um modelo que possibilita aos usuários novos na comunidade, receber recomendações com apenas uma indicação de confiança;
- A apresentação de um modelo de Sistema de Recomendação baseado na confiança do usuário;
- A indicação de caminhos para aprofundamento de pesquisas com Sistemas de Recomendação utilizando Redes de Confiança dos usuários;
- A especificação e implementação de um protótipo integrado à comunidade virtual ActivUFRJ, possibilitando a ampliação da proposta e o desenvolvimento de novas pesquisas;
- A apresentação dos resultados obtidos a partir de dois estudos que contribuíram para verificar a viabilidade da solução apresentada para o problema da dissertação e que podem servir como base para a realização de novos estudos e trabalhos futuros.

### **7.3 Trabalhos futuros**

Essa dissertação aponta algumas sugestões para trabalhos futuros, tanto em nível teórico, como de desenvolvimento de novas aplicações e realização de novos estudos de caso. A seguir, são apresentadas as perspectivas para o prosseguimento dessa pesquisa:

- Investigação e desenvolvimento de experimentos que minimizem os problemas relativos à filtragem colaborativa;
- Estudo de outras técnicas para incentivar a integração de novos usuários dentro de comunidades virtuais;
- Desenvolvimento de estudos de caso envolvendo a propagação da confiança dos usuários da comunidade para gerar recomendações;
- A utilização da reputação dos membros da comunidade como fator para gerar a Rede de Confiança implícita entre os usuários, Cruz *et al.* (2007);
- Aplicação de técnicas de combinação social com base na Rede de Confiança do usuário e interesses similares entre os membros;
- Criação e desenvolvimento de algoritmos e técnicas capazes de criar a Rede de Confiança dos usuários implicitamente;
- Investigar a desconfiança entre usuários como fator para gerar recomendações;
- Permitir melhores maneiras para o usuário visualizar e modificar a Rede de Confiança, além de investigar como a rede pode ajudar o usuário a receber recomendações e até controlá-las.
- Criação e desenvolvimento de algoritmos e técnicas capazes de gerar recomendações mais confiáveis;
- Investigação e desenvolvimento do modelo proposto em outras áreas de aplicação para avaliar sua flexibilidade quanto à área de atuação;
- Implementação de ferramentas de comunicação (fórum, *chat*, editor colaborativo) e mecanismos de percepção (saber quem está *on-line*, entender o contexto das informações compartilhadas) para melhorar a interação entre os membros do ActivUFRJ;

- Investigação de outros métodos de pesquisa que forem necessários para validar hipótese da dissertação;

Por fim, acredita-se que o modelo proposto nessa dissertação referente a Sistemas de Recomendação tem um potencial não só para aplicação em Comunidades Virtuais, mas também em outros ambientes que envolvam o compartilhamento de informações entre usuários, visto que é importante dar atenção para a confiança do usuário e na sua satisfação quanto ao reconhecimento de que pessoas confiáveis influenciam nas recomendações recebidas.



## REFERÊNCIAS

ABDUL-RAHMAN, A ; HAILES, S. A distributed trust model. In: NEW SECURITY PARADIGMS 1997, Langdale. **Proceedings** ... Langdale: ACM, 1997. p. 48-60.

\_\_\_\_\_; \_\_\_\_\_. Supporting trust in virtual communities. In: ANNUAL HAWAII INTERNATIONAL CONFERENCE ON SYSTEM SCIENCES, 33., 2000, Maui. **Proceedings** ... Maui: IEEE, 2000. v.1.

ADOMAVICIUS, G. ; TUZHILIN, A., Toward the next generation of recommender systems: a survey of the state-of-the-art e possible extensions. **IEEE Transactions on Knowledge e Data Engineering**. Piscataway, v.17 n.6, p.734-749, Jun. 2005.

AGGARWAL, C. C. et al. Horting hatches an egg: a new graph-theoretic approach to collaborative filtering. In: ACM SIGKDD INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY & DATA MINING,5., 1999, San Diego. **Proceedings** ... New York, 1999. p. 201-212.

AGRAWAL, R. ; SRIKANT, R. Fast algorithms for mining association rules. In: INTERNATIONAL CONFERENCE ON VERY LARGE DATA BASES, 20., 1994, Santiago, Chile. **Proceedings** ... San Francisco: Morgan Kaufmann, 1994. p. 487-499.

ANSARI, A. et al. Internet recommendation systems, **Journal of Marketing Research**, Chicago, Ill, v.37, n.3, p. 363-375, Aug. 2000.

BACHARACH, M. ; GAMBETTA, D. Trust in signs. In: COOK, Karen (ed.) **Social structure and trust**. Nova York: Russell Sage Foundation, 2000.

BAEZA-YATES, R.; RIBEIRO-NETO, B. **Modern information retrieval**. Edinburgh Gate : Addison-Wesley, 1999.

BALABANOVIC, M. ; SHOHAM, Y. Fab: content-based, collaborative recommendation. **Communications of the ACM** , Nova York, v.40, n.3, p. 66-72, Mar. 1997.

BASU, C. ; HIRSH, H. ; COHEN, W. Recommendation as classification: using social and content-based Information in recommendation. In: NATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE. 1998, Madison. **Proceedings** ... Menlo Park: AAAI, 1998. p. 714-720.

BEEFERMAN, D. ; BERGER, A. Agglomerative clustering of a search engine query log. In: ACM SIGKDD INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING, 6., 2000, Boston. **Proceedings** ... New York, 2000. p. 407-416, 2000.

BELLINI, C. G. P. ; MANSSOUR, A. B. B. Understanding the sucess of an Internet-mediated community in Brazil. In: ANNUAL GLOBAL INFORMATION TECHNOLOGY

MANAGEMENT WORLD CONFERENCE, 6., 2005, Anchorage, AK. **Proceedings ...** Greensboro, NC: GITMA, 2005. p. 105-108.

BILLSUS, D. ; PAZZANI, M. User modeling for adaptive news access. **User modeling and user-adapted interaction**, Dordrecht, v.10, n.2-3, p. 147-180, 2000.

BREESE, J. ; HECKERMAN, D. ; KADIE, C. Empirical analysis of predictive algorithms for collaborative filtering. In: CONFERENCE ON UNCERTAINTY IN ARTIFICIAL INTELLIGENCE, 14., 1998. Madison. **Proceedings ...** Madison: University of Wisconsin Business School, 1998. p. 43-52.

CAZELLA, S. C. ; ALVARES, L. O. C., Creating virtual web communities through a hybrid recommender system. In: WORKSHOP DE TESES E DISSERTAÇÕES EM INTELIGÊNCIA ARTIFICIAL, 2., 2004. São Luis. **Proceedings ...** São Luis: SBIA, 2004. p. 51-60.

CHIEN, Y.-H. ; GEORGE, E. I. A bayesian model for collaborative filtering. In: INTERNATIONAL WORKSHOP ARTIFICIAL INTELLIGENCE AND STATISTICS, 7., 1999, Fort Lauderdale. **Proceedings ...** Fort Lauderdale: The Society for Artificial Intelligence & Statistics, 1999.

CLAYPOOL, M. et al. Combining content-based and collaborative filters in an online newspaper. In: ACM SIGIR '99 WORKSHOP RECOMMENDER SYSTEMS: ALGORITHMS AND EVALUATION, 1999. Berkeley. **Proceedings ...** Berkeley, 1999.

COLEMAN, J. **Foundations of social theory**. Cambridge: Harvard University Press, 1990.

CONDLIFF, M. et al. Bayesian mixed-effects models for recommender systems. . In: ACM SIGIR '99 WORKSHOP RECOMMENDER SYSTEMS: ALGORITHMS AND EVALUATION, 1999. Berkeley. **Proceedings ...** Berkeley, 1999.

COOK, K. ; COOPER, R. Experimental studies of cooperation, trust, and social exchange. In: OSTROM, E. ; WALKER, J. (Ed) **Trust and reciprocity**. New York: Russell Sage Foundation, 2003. p. 209-244

CRUZ, C. C. P. ; MOTTA, C. L. R. ; SANTORO, F. M. ReCoP: um modelo para reputação em comunidades de prática. In: SIMPÓSIO BRASILEIRO DE INFORMÁTICA NA EDUCAÇÃO, 17. 2007, São Paulo. **Anais ...** São Paulo: SBIE, 2007.

DELGADO, J. ; ISHII, N. Memory-based weighted-majority prediction for recommender systems. In: ACM SIGIR '99 WORKSHOP RECOMMENDER SYSTEMS: ALGORITHMS AND EVALUATION, 1999. Berkeley. **Proceedings ...** Berkeley, 1999.

DEUTSCH, M. Cooperation and trust: some theoretical notes. In: JONES, M. R. (Ed.) **Nebraska Symposium on Motivation**. Lincoln: Nebraska University Press, 1962.

DIEBERGER, A. et al. Social navigation: techniques for building more usable systems. **Interactions**, New York, v.7 n.6, p.36-45, Nov./Dec. 2000.

ERICKSON, T. ; KELLOGG, W. A. Social translucence: an approach to designing systems that support social processes. **ACM Transactions on Human Computer Interaction** , New York, v. 7, n. 1, p. 59–83, Mar. 2000.

FOLTZ, P. W. ; DUMAIS, S. T. Personalized information delivery: an analysis of information filtering methods. **Communications of the ACM**, New York, v.35, n.12, p. 51-60, Dec., 1992.

GARDEN, M. ; DUDEK, G. Semantic feedback for hybrid recommendations in Recommendz. In: IEEE INTERNATIONAL CONFERENCE ON ETECHNOLOGY, E-COMMERCE AND E-SERVICE. 2005, Hong Kong. **Proceedings ...** Los Amigos , 2005.

GARNBETTA, D. Can we trust trust ?. In: GAMBETTA, D. (Ed.). **Trust: making and breaking cooperative relations**. Oxford: Basil Blackwell, 2002. p. 213-237.

GAUTSCHI, T. History effects in social dilemma situations. **Rationality & Society**, Newbury Park, CA, v. 12, n. 2, p.131-163, 2000.

GETOOR, L. ; SAHAMI, M. Using probabilistic relational models for collaborative filtering. In: SPILIOPOULOU, M. ; MASAND, B. **Web usage analysis and user profiling**: International WEBKDD' 99 Workshop. Berlin: Springer Verlag, 2000. (Lecture Notes in Computer Science, v. 1836).

GOLBECK, J. Computing and applying trust in web-based social networks. 2005. Tese ( Doctorate in Computer Science ) – Computer Science Department, University of Maryland, , Maryland , 2005. 184 f.

\_\_\_\_\_. Generating predictive movie recommendations from trust in social networks. In: INTERNATIONAL CONFERENCE ON TRUST MANAGEMENT, 4, 2006, Pisa. **Proceedings ...** Pisa: Istituto de Informatica e Telematica Del CNR, 2006.

GOLBECK J. ; HENDLER, J. ; PARSIA, B. Trust networks on the semantic web. In: INTERNATIONAL WORKSHOP ON COOPERATIVE INTELLIGENT AGENTS, 7., 2003. Helsinki. **Proceedings ...** New York: ACM, 2003.

GOLDBERG, D. et al. D. Using collaborative filtering to weave an information tapestry. **Communications of the ACM**, New York, v. 35, n.12, p. 61-70, Dec. 1992.

GOLDBERG, K. et al. Eigentaste: a constant time collaborative filtering algorithm. **Information Retrieval**, Boston, v.4, n.2, p. 133-151, Jul. 2001.

GOOD, N. et al. Combining collaborative filtering with personal agents for better recommendations. In: NATIONAL CONFERENCE ON ARTIFICIAL INTELIGENCE, 16, 1999, Orlando. **Proceedings ...** Menlo Park: AAI, 1999. p. 439-446.

GORI, M. ; WITTEN, I. The bubble of web visibility. **Communications of the ACM**, New York, v.48, n.3, p. 115-117, Mar. 2005.

GRAY, E. et al. **Towards a framework for assessing trust-based admission control in collaborative ad hoc Applications**. Dublin: Dept. of Computer Science, Trinity College Dublin, 2002. ( Technical Report 66).

GUHA, R. et al. Propagation of trust and distrust. In: INTERNATIONAL CONFERENCE ON WORLD WIDE WEB, 13., 2004., New York. **Proceeding ...** New York: ACM, 2004. p. 403-412.

HARDIN, R. Distrust. In: RUSSELL SAGE FOUNDATION CONFERENCE ON DISTRUST, 1997. Bellagio, Italy. **Proceedings ...**, Bellagio, Italy,. 1997. p.13-17.

HARDIN, R. ; COOK, K. Norms of cooperativeness and networks of trust. In: HECHTER, M. ; OPP, K-D. (Eds). **Social norms**. Nova York: Russell Sage Foundation,2001. p. 327-47.

HERLOCKER, J. et al. Evaluating collaborative filtering recommender systems. **ACM Transactions on Information Systems**, New York, v. 22, n. 1, p. 5-53, Jan., 2004.

HERLOCKER, J. **Understanding and improving automated collaborative filtering systems**. 2000.Dissertation (Ph.D ). University of Minnesota. Disponível em: <http://web.engr.oregonstate.edu/~herlock/papers.html>. Acesso em: 2000.

HERLOCKER, et al. An algorithm framework for performing collaborative filtering. In: ANNUAL INTERNATIONAL ACM SIGIR CONFERENCE ON RESEARCH AND DEVELOPMENT IN INFORMATION RETRIEVAL, 22., 1999, Berkeley. **Proceedings ...** Nova York, 1999. p. 77-87.

HERLOCKER, J., et al. Explaining collaborative filtering recommendations, 2000 ACM CONFERENCE ON COMPUTER SUPPORTED COOPERATIVE WORK, 2000. Philadelphia. **Proceedings ...** Philadelphia, 2000. p..241-250.

HILDENBRAND, A. **ActivUFRJ**: ambiente colaborativo de trabalho integrado e virtual. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) – Instituto de Matemática, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2006.

HILL, W. et al. Recommending and evaluating choices in a virtual community of use. In: SIGCHI CONFERENCE ON HUMAN FACTORS IN COMPUTING SYSTEMS, 1995, Denver. **Proceedings ...** .New York: ACM, 1995. p.194-201.

HOFMANN, T. Latent semantic models for collaborative filtering. **ACM Transactions on Information Systems**, New York, v. 22, n. 1, p. 89-115, Jan. 2004.

IGARASHI, T. et al. Culture, trust, and social networks. **Asian Journal Of Social Psychology**, London, v. 11, n. 1, pg. 88-101, Mar. 2008.

JONES, G. R. ; GEORGE, J. M. The Experience and evolution of trust: implications for cooperation and teamwork. **Academy of Management Review**, Mississippi, v. 23, n. 3, p. 531-546, 1998.

JOSANG, A. The right type of trust for distributed systems. In: NEW SECURITY PARADIGMS, 1996, Lake Arrowhead. **Proceedings ...** New York: ACM, 1996.

JOSANG, A. ; ISMAIL, R. ; BOYD, C. A Survey of trust and reputation systems for online service provision. **Decision Support Systems**, Amsterdam, v. 43, n. 2, Mar. 2007. p. 618-644.

KAMVAR, S. et al. Extrapolation methods for accelerating PageRank computations. In: INTERNATIONAL WORLD WIDE WEB CONFERENCE, 12., 2003, Budapest . **Proceedings ...** New York: ACM, 2003. p. 261-270

KAUTZ, H. et al. Referral web: combining social networks and collaborative filtering. **Communications of the ACM**, New York, v.40, n.3, pg. 63-65, Mar., 1997.

KHARE, R. ; RIFKIN, A. XML: a door to automated web applications. **IEEE Internet Computing**, Piscataway, v. 1, n. 4, p. 78-87, Jul.-Aug. 1997.

KITTS, B. ; FREED, D. ; VRIEZE, M. Cross-sell: a fast promotion-tunable customer-item recommendation method based on conditional independent probabilities. In: ACM SIGKDD INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING, 6., 2000, Boston. **Proceedings ...** New York, 2000. p. 437-446.

KONSTAN, J. et al. GroupLens: applying collaborative filtering to usenet news. **Communications of the ACM**, New York, v. 40, n.3, pg. 77-87, Mar. 1997.

KUMAR, R. et al. A. Recommendation systems: a probabilistic analysis. **Journal of Computer and Systems Sciences**, New York, v. 63, n.1, pg. 42-61, Aug. 2001.

LANG, K. Newsweeder: learning to filter netnews. In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING, 12., Tahoe City, CA. **Proceedings ...** San Francisco: Morgan Kaufmann, 1995.

LEVI, M. A State of trust. In: LEVI, M. ; BRAITHWAITE, V. (Eds.) **Trust and governance**. New York: Russell Sage Foundation, 1998.

LEVIEN, R. **Attack-resistant trust metrics**. 2001. Thesis (Doctorate of Philosophy in Computer Science). University of California at Berkeley , Berkeley, 2001.

LIN, N. ; FU, Y-C. Social capital: social networks, civic engagement, or trust?. In: WORKSHOP ON SOCIAL CAPITAL, 2000. Trento. **Proceedings ...** Trento: Department of Sociology and Social Research , University of Trento, 2000.

LIU B. ; HSU, W. ; MA, Y. Integrating classification and Association Rule Mining. In: INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING, 4., 1998, New York. **Proceedings ...** New York: AAAI,

LUHMAN, N. **Trust and power**. New York, John Wiley, 1979.

MALINOWSKI, J. et al. Decision support for team building: incorporating trust into a recommender-based approach. In: PACIFIC ASIA CONFERENCE ON INFORMATION SYSTEMS, 9., 2005, Bangkok. **Proceedings ...** Bangkok: KU-INOVA, 2005, p. 604-617.

MARSH, S. **Formalising trust as a computational concept**. 1994. Thesis (Doctoral in Philosophy), Department of Computing Science and Mathematics, University of Stirling, Scotland, 1994.

MARLIN, B. Modeling user rating profiles for collaborative filtering. In: ANNUAL CONFERENCE ON NEURAL INFORMATION PROCESSING SYSTEMS, 17., 2003, Vancouver. **Proceedings ...** Vancouver: Neural Information Processing Systems Foundation, 2003.

MASSA, P. ; BHATTACHARJEE, B. Using trust in recommender systems: an experimental analysis. INTERNATIONAL CONFERENCE ON TRUST MANAGEMENT, 2. 2004, Oxford, UK. **Proceedings ...** Oxford, England: St Anne's College, 2004.

MASSA, P. ; AVESANI, P. Trust-aware collaborative filtering for recommender systems. In: INTERNATIONAL CONFERENCE ON COOPERATIVE INFORMATION SYSTEMS, 2004, Napa, Cyprus. **Proceedings ...** Berlin: Springer Verlag, 2004.

MASSA, P.; HAYES, C. Page-rerank: using trusted links to re-rank authority. In IEEE/WIC/ACM INTERNATIONAL CONFERENCE ON WEB INTELLIGENCE, 2005, Compiègne. **Proceedings ...** Compiègne: IEEE/IC/ACM, 2005. p. 614-617.

MCCAREY, F. ; CINNÉIDE, M. Ó.; KUSHMERICK, N. Rascal: a recommender agent for agile reuse. **Artificial Intelligence Review**, Dordrecht, v. 24, n. 3-4, p. 253-276, Nov. 2005.

MELVILLE, P. ; MOONEY, R.J. ; NAGARAJAN, R. Content-boosted collaborative filtering for improved recommendations. NATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE, 18., 2002. Edmonton. **Proceedings ...** Menlo Park: AAAI, 2002.

MOBASHER, B. ; COOLEY, R. ; SRIVASTAVA, J. Automatic personalization based on web usage mining. **Communications of the ACM**, New York, v.43, n.8, p. 142-151, Aug. 2000.

MONTANER, M. ; LÓPEZ, B. ; LA ROSA, J. L. Developing trust in recommender agents. In: INTERNATIONAL JOINT CONFERENCE ON AUTONOMOUS AGENTS AND MULTIAGENT SYSTEMS, 1., 2002, Bologna. **Proceedings ...** New York: ACM, 2002. pt. 1 .p. 304-305.

MOVIELENS 2004. **GroupLens research at the University of Minnesota**. Disponível em: <http://www.grouplens.org>. Acessado em: 01 nov. 2006.

NAKAMURA, A. ; ABE, N. Collaborative filtering using weighted majority prediction algorithms. In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING, 15., 1998, Madison. **Proceedings ...** San Francisco: Morgan Kaufmann, 1998.

PAGE, L. et al. **The pagerank citation ranking: bringing order to the web**. Stanford: Stanford University, 1998. (Stanford InfoLab Publication Service).

PAZZANI, M. ; BILLSUS, D. Learning and revising use profiles: the identification of interesting web sites. **Machine Learning**, Dordrecht, v. 27, n. 3, p. 313-331, Jun. 1997.

PAVLOV, D. ; PENNOCK, D. A Maximum entropy approach to collaborative filtering in dynamic, sparse, high-dimensional domains. In: NEURAL INFORMATION PROCESSING SYSTEMS, 2002, Vancouver. **Proceedings** ... Vancouver: NeuralInformation Processing Systems Foundation, 2002.

PAZZANI, M. A Framework for collaborative, content-based, and demographic filtering. **Artificial Intelligence Review**, Dordrecht, v. 13, n. 5-6, p. 393-408, Dec. 1999.

PENNOCK, D.M. ; HORVITZ, E. Collaborative filtering by personality diagnosis: a hybrid memory and model-based approach. In: WORKSHOP ON MACHINE LEARNING FOR INFORMATION FILTERING, 1999. Stockholm. **Proceedings** ... San Francisco: Morgan Kaufmann, 1999.

POE, V. ; BROBST, S. ; KLAUER, P. **Building a data warehouse for decision support**. 2ed. Upper Saddle River: Prentice-Hall, 1998.

POPESCU, A. et al. Probabilistic models for unified collaborative and content-based recommendation in sparse-data environments. CONFERENCE ON UNCERTAINTY IN ARTIFICIAL INTELLIGENCE, 17., 2001, Seattle. **Proceedings** ... San Francisco: Morgan Kaufmann, 2001. p. 329-333.

RESNICK, P. ; VARIAN, H. R. Recommender systems. **Communications of the ACM**, New York, v.40, n.3, p. 56-58, Mar. 1997.

RESNICK, P. et al. GroupLens: an open architecture for collaborative filtering of netnews. In: CONFERENCE ON COMPUTER SUPPORTED COOPERATIVE WORK, 1994, Chapel Hill. **Proceedings** ... New York: ACM, 1994. p. 175-186.

RESNICK, P. et al. Reputation systems. **Communications of the ACM**, New York, v.43, n.12, p. 45-48, Dec. 2000.

RICH, E. User modeling via stereotypes. **Cognitive Science**, Kidlington Oxford, v.3, n.4, p. 329-354, Oct.-Dec. 1979.

RICHARDSON, M. ; ARGAWAL, R. ; DOMINGOS, P. Trust management for the semantic web. In: INTERNATIONAL SEMANTIC WEB CONFERENCE, 2., 2003, Sanibel Island. **Proceedings** ... Sanibel Island: SWSA, 2003. p. 351-368.

ROBINSON, R. ; JACKSON, E. Is trust in others declining in America?: an age-period-cohort analysis. **Social Science Research**, New York, v.30, n. 1, p. 117-145, 2001.

ROTTER, J.B. Generalized expectancies for interpersonal trust. **American Psychologist**, Washington, v. 26, n. 5, p. 443-450, 1971.

SALTON, G. **Automatic text processing**. Reading: Addison-Wesley, 1989.

SARWAR, B. et al. Application of dimensionality reduction in recommender systems: a case study. In: ACM WEBKDD WORKSHOP, 2000, Boston. **Proceedings ...** New York: ACM, 2000.

SARWAR, B. et al. J. Item-based collaborative filtering recommendation algorithms. In: INTERNATIONAL WORLD WIDE WEB CONFERENCE, 10., 2001, Hong Kong. **Proceedings ...** New York: ACM, 2001.

SCHAFFER, J. ; KONSTAN, J.; RIEDL, J. Recommender systems in e-commerce. In: ACM CONFERENCE ON ELECTRONIC COMMERCE, 1., 1999. Denver. **Proceedings ...** New York, 1999.

SCHEIN, A.I. et al. Methods and metrics for cold-start recommendations. In ANNUAL INTERNATIONAL ACM SIGIR CONFERENCE ON RESEARCH AND DEVELOPMENT IN INFORMATION RETRIEVAL, 25., 2002, Tampere. **Proceedings ....** New York, 2002.

SHANI, G. ; BRAFMAN, R. ; HECKERMAN, D. An MDP-Based recommender system. In: CONFERENCE UNCERTAINTY IN ARTIFICIAL INTELLIGENCE, 18., 2002. Edmonton. **Proceedings ...** San Francisco: Morgan Kaufmann, 2002.

SHARDANAND, U. ; MAES, P. Social information filtering: algorithms for automating "word of mouth". In: SIGCHI CONFERENCE ON HUMAN-FACTORS IN COMPUTING SYSTEMS, 1995, Denver. **Proceedings ...** New York: ACM, 1995. p. 210-217.

SI, L.. ; JIN, R. Flexible mixture model for collaborative filtering. In: INTERNATIONAL CONFERENCE MACHINE LEARNING, 20. 2003. Washington, DC. **Proceedings ...** Menlo Park: AAAI Press, 2003.

SOBOROFF, I. ; NICHOLAS, C. Combining content and collaboration in text filtering. In: WORKSHOP ON MACHINE LEARNING FOR INFORMATION FILTERING, 1999. Stockholm. **Proceedings ...** San Francisco: Morgan Kaufmann, 1999.

TERVEEN, L. G. ; MCDONALD, D. W. Social matching: a framework and research agenda. In: **ACM Transactions on Computer-Human Interaction (ToCHI)**, New York, v.12, n.3, p. 401-434, Sep. 2005.

TERVEEN, L. et al. A system for sharing recommendations. **Communications of the ACM**, New York, v.40, n.3, pg. 59-62, Mar. 1997.

TRAN, T. ; COHEN, R. Hybrid recommender systems for electronic commerce. In: AAAI-00 WORKSHOP ON KNOWLEDGE-BASED ELECTRONIC MARKETS, 2000. Austin. **Proceedings ...** . Menlo Park: AAAI Press, 2000. También: Technical Report WS-000-04, AAAI Press, 2000.

UNGAR, L.H. ; FOSTER, D.P. Clustering methods for collaborative filtering. In: WORKSHOP ON RECOMMENDATION SYSTEMS AT THE NATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE, 15., 1998. Madison. **Proceedings ...** Menlo Park: AAAI Press, 1998. También: Technical Report WS-98-08, 1998.



YAMAGISHI, T. **Trust and social intelligence: the evolutionary game of mind and society.** Tóquio: Tokyo University Press, 1998.

YAMAGISHI, T. ; KIKUSHI, M. ; KOSUGI, M. Trust, gullibility and social intelligence. **Asian Journal of Social Psychology**, London, v.2, n.1, p. 145-161, Apr. 1999.

YAMAGISHI, T. ; YAMAGISHI, M. Trust and commitment in the United States and Japan. **Motivation and Emotion**, New York, v.18, n.2, p. 129-166, Jun. 1994.

YU, K. et al. Instance selection techniques for memory-based collaborative filtering. SIAM INTERNATIONAL CONFERENCE ON DATA MINING, 2., 2002. Arlington. **Proceedings** .... Philadelphia, 2002.

ZHANG, Y. ; CALLAN, J. ; MINKA, T. Novelty and redundancy detection in adaptive filtering. In: ANNUAL INTERNATIONAL ACM SIGIR CONFERENCE ON RESEARCH AND DEVELOPMENT IN INFORMATION RETRIEVAL, 25., 2002, Tampere: **Proceedings** ... New York: ACM, 2002. p. 81-88.

ZIEGLER, C. ; LAUSEN, G. Analyzing correlation between trust and user similarity in online communities. In: INTERNATIONAL CONFERENCE ON TRUST MANAGEMENT, 2., 2004, Oxford, UK. **Proceedings** ... Oxford, England: St Anne's College, 2004.

# ANEXO A - CÓDIGOS DO MATLAB

Nesse anexo são apresentadas todas as funções utilizadas para os experimentos dentro do MATLAB.

## Estatísticas da base de dados

Este código é utilizado para calcular as estatísticas das base de dados geradas.

### Stats.m

```
[uid, mid, r]=textread('u.data','%u %u %u %*u');
list=[uid mid r];
clear uid mid r

rnum=length(list);

mat_base= list2mat(list);

% calcula media and mediana
fprintf('\nMean Value is %1.2f, median is
%1.2f\n',mean(list(:,3)),median(list(:,3)));

% plot historgrama de score
hist(list(:,3),[1 2 3 4 5]);
xlabel('Score')

% numero de filmes avaliados, histograma e media
mr=full(sum(mat_base~=0));
fprintf('The average number of ratings per movie is %2.1f\n',mean(mr));
hist(mr,50)
xlabel('Number of Scores for Movie')

% numero de avaliações de filmes
mu=full(sum(mat_base~=0,2));
fprintf('The average number of ratings per user is %2.1f\n',mean(mu));
hist(mu,50)
xlabel('Number of Scores Per User')

% dispersão das avaliações
spy(mat_base)
xlabel('Movie ID')
ylabel('User ID')
```

### List2Mat.m

Esta função converte a lista inteira em uma matriz esparsa.

```
function mat=list2mat(list)
% USAGE: mat=list2mat(list)
% Esta função converte uma lista (UID, MID, R) em uma matriz esparsa U x M
= R
```

```

mat=0;
mat=sparse(mat);
l=length(list);
h=waitbar(0,'Processando List2Mat');
for i=1:l,
    if mod(i,2000)==0 waitbar(i/l,h); end
    mat(list(i,1),list(i,2))=list(i,3);
end
close(h)

```

## Mkdata.m

Este código é utilizado para fazer uma matriz treino e uma matriz teste.

```

function [base_mat, test_list]=mkdata(mat_base,varargin)

% USAGE:[base_mat, test_list]=mkdata(mat_base,r,tnum,mnum,unum)
%
% base_mat-   matriz treino
% test_list-   matriz teste
% mat_base-   matriz esparsa contendo todo conteúdo
% r-         ratio of users tested (default= 0.1)
% tnum-      number of movies tested per user (default = 5)
% mnum-      number of movies in output data (default= base_mat)
% unum-      number of users in output data (default = base_mat)

r=0.1; % percent of users tested
[unum, mnum]=size(mat_base); % default matrix size, untruncated
tnum=5;

if nargin>=2
    r=varargin{1};
end
if nargin>=3
    tnum=varargin{2};
end
if nargin>=4
    mnum=varargin{3};
end
if nargin==5
    unum=varargin{4};
end
if (nargin<1 | nargin>5)
    error('Improper number of input arguements');
end

base_mat=mat_base(1:unum,1:mnum); % truncate matrix if necessary

n_u_tst=round(r*unum); % number of users tested
p=randperm(unum);      % randomize user index

for i=1:n_u_tst,
    idx=find(base_mat(p(i),:)==0); % indices of rated movies of user
    ns=length(idx); % number of scored items
    rs=randperm(ns); % randomize scored movie index
    for j=1:tnum, % select 5 random movies for each user
        test_list((i-1)*tnum+j,:)=p(i) idx(rs(j))
    mat_base(p(i),idx(rs(j)))];
    base_mat(p(i),idx(rs(j)))=0;
end

```

```

    end
end

[tmp,index]=sort(test_list,1); % sort _test_list_ according to user number
test_list=test_list(index(:,1),:);

```

## Predições

Função para encontrar as predições sobre as avaliações pelos 3 métodos

```

function list_pred=pearscorrelacao(mat_base,list_test, varargin);
% Esta função utiliza a matriz de avaliações (UxM,R) e uma lista de observações (uid, mid, r)
% return: uma lista de predições utilizando Pearson r.
%
% USAGE: list_pred=pearsnn(mat_base,list_test,pears_th, users_th, herlck_th)
% list_pred- uma lista [uid mid r pred u_ave]
%
% mat_base- base de dados na forma de matriz esparsa
% list_test- lista teste na forma de [uid mid r], não precisa estar ordenada
% Parâmetros opcionais:
% pears_th- coeficiente de corte Pearson (default=0.1)
% users_th- número mínimo de usuários correlatos para realizar a predição (default=6)
% herlck_th- número mínimo de filmes ranqueados entre usuários (default=25)

herlck_th=25;
pears_th=0.1;
users_th=3;

if nargin>=3
    pears_th=varargin{1};
end
if nargin>=4
    users_th=varargin{2};
end
if nargin==5
    herlck_th=round(varargin{3});
end
if (nargin<2 | nargin>5)
    error('Número de campos errado');
end

[tmp,index]=sort(list_test,1); % ordena _list_test_ de acordo com o número de usuários
list_test=list_test(index(:,1),:);

[unum,mnum]=size(mat_base);
num_test=size(list_test,1);
prev_user=0;
count=1;
conta=1;
contaa=1;
P=zeros(unum,unum);

user_mean=sum(mat_base,2)./sum(mat_base~=0,2); % vetor de media de avaliação de cada usuário
mat_ave=(mat_base-repmat(user_mean,1,mnum)).*(mat_base~=0);
% matriz de avaliação menos a media de cada usuário, 0 para itens não avaliados
vpears=0;

```

```

vpears=sparse(vpears);

h=waitbar(0,'Processando Pearson...');

for i=1:num_test, % encontra a correlação entre todos os usuários
    user=list_test(i,1);
    mid=list_test(i,2);
    if prev_user~=user; % a distância é recalculada sempre que um novo usuário é encontrado
        prev_user=user;
        ref= repmat(mat_ave(user,:), unum, 1);
        % repete a matriz de usuário teste menos a média, 0 para itens não avaliados

        rated=(mat_ave~=0).*(ref~=0); % itens avaliados em comum...
        srated=sum(rated,2); % número de itens avaliados em comum
        cv=sqrt(sum((mat_ave.^2).*rated,2).*sum((ref.^2).*rated,2)+(sum(rated,2)==0));
        % cobertura entre o usuário e outros, 1 se não tiver (para permitir divisão por 0)
        pr=(sum(rated,2)~=0).*sum(ref.*mat_ave.*rated,2)./cv;
        % Coef. Pearson r entre o usuário e outros, se não tiver correlação pr=0
        % deve ser entre [-1,1], valores absolutos altos significam grande correlação
        pr=srated/herlck_th.*pr.*(srated<=herlck_th)+pr.*(srated>herlck_th);
        %pr=(srated/herlck_th).^2.*pr.*(srated<=herlck_th)+pr.*(srated>herlck_th);
        % add herlock, usada para entender a influencia de usuários recém iniciados...
        w=(abs(pr)>=pears_th).*sign(pr).*(abs(pr)-pears_th)/(1-pears_th);
        % Cria o peso do coef. Pearson r, usado para incorporar na classificação
        [a,b] = size(w);
        for j=1:a,
            P(user,j)=pr(j,1);
        end
        prev_user=user;
    end

    if mod(i,25)==0 waitbar(i/num_test,h); end

end

%%gera as predições para Filtragem Colaborativa Tradicional, essa parte
deve ser comentada se não for FC
num_itens=0;
recomenda=1;
[a,b]=size(mat_ave);
aux=0;
qtd=0;
y=[0];
totalrecomenda=0;
auxPears=0;
recd=[0 0];

[uid, mid, r]=textread('ul.base','%u %u %u %*u'); % tabela que será
comparado
listT=[uid mid r];
clear uid mid r

rnumT=length(listT);
mat_baseT= list2mat(listT);

for i=1:a, % usuário alvo da recomendação
    %     %if (recomenda<100)
    %     i
    %     recomenda

```

```

for k=1:b, % itens da base de dados
    if (mat_base(i,k)==0)&&(mat_baseT(i,k)>0)
        for j=1:a, % usuários para comparar
            if (P(i,j)>=pears_th)&&(j~=i)&&(mat_base(j,k)~=0)
                aux = aux + ((mat_base(j,k)-user_mean(j))*P(i,j));
% numerador
                auxPears = auxPears + P(i,j); % denominador
                qtd = qtd + 1;
            end
        end
        if (qtd>=users_th)
            z(recomenda,1)=i; % usuário
            z(recomenda,2)=k; % item
            score=user_mean(i)+(aux/auxPears);
            score=(score<=1)+score*((score<5)&(score>1))+5*(score>=5);
            z(recomenda,3)=score; % predição da avaliação
            z(recomenda,4)=mat_baseT(i,k); % avaliação real
            z(recomenda,5)=qtd; % qtd de pessoas que afetaram na
recomendação
recomendações
recomendações do usuário
            totalrecomenda = totalrecomenda+1; % conta as
            end
            aux=0;
            auxPears=0;
            qtd=0;
        end
    end
    y(i,:)=[totalrecomenda]; % total de recomendações de cada usuário
    totalrecomenda=0;
%end
end
list_pred= z;

%%fim gera as predições para Filtragem Colaborativa Tradicional

%%gera as predições pela confiança implícita Pearson
num_itens=0;
recomenda=1;
[a,b]=size(mat_base);
aux=0;
qtd=1;
y=[0];
totalrecomenda=0;
auxPears=0;
fatorConfianca=0.4;
z=[0];
novoUsuario=0;

[uid, mid, r]=textread('ul.base','%u %u %u %*u'); % tabela que será
comparado
listT=[uid mid r];
clear uid mid r

rnumT=length(listT);
mat_baseT= list2mat(listT);

% ajuste para criar os níveis de confiança

```

```

C=zeros(unum,unum);
soma=0;
for i=1:a,
    for j=1:a,
        if(i~=j)
            if (P(i,j)>=0.4)&&(P(i,j)<0.5)
                C(i,j)=0.2;
            end
            if (P(i,j)>=0.5)&&(P(i,j)<0.6)
                C(i,j)=0.4;
            end
            if (P(i,j)>=0.6)&&(P(i,j)<0.7)
                C(i,j)=0.6;
            end
            if (P(i,j)>=0.7)&&(P(i,j)<0.8)
                C(i,j)=0.8;
            end
            if (P(i,j)>=0.8)&&(P(i,j)<0.9)
                C(i,j)=0.9;
            end
            if (P(i,j)>=0.9)
                C(i,j)=1;
            end
            if (C(i,j)>0)
                z(qtd,1)=[C(i,j)];
                qtd=qtd+1;
                aux=1;
            end
        end
        if (P(i,j)>=0.4)&&(j~=i)
            soma=soma+1;
        end
        if (soma>=10)
            break;
        end
    end
    if (aux==1)&&(length(find(list_test(:,1)==i))<=10)
        novoUsuario=novoUsuario+1
    end
    aux=0;
    y(i,1)=[soma];
    soma=0;
end

for i=1:a, % usuário alvo da recomendação
    for k=1:b, % itens da base de dados
        if (mat_base(i,k)==0)&&(mat_baseT(i,k)>0)
            for j=1:a, % usuários para comparar
                if (P(i,j)>=pears_th)&&(j~=i)&&(mat_base(j,k)~=0)
                    aux = aux + ((mat_base(j,k)-user_mean(j))*P(i,j));
                end
            end
            % numerador
            auxPears = auxPears + P(i,j); % denominador
            qtd = qtd + 1;
        end
    end
    if (qtd>=users_th)
        z(recomenda,1)=i; % usuário
        z(recomenda,2)=k; % item
        score=(aux/auxPears);
    end
end

score=(score<=1)+score*((score<5)&(score>1))+5*(score>=5);

```

```

        z(recomenda,3)=score; % predição da avaliação
        z(recomenda,4)=mat_baseT(i,k); % avaliação real
        z(recomenda,5)=qtd; % qtd de pessoas que afetaram na
recomendação
        recomenda=recomenda+1; % contagem geral do vetor de
recomendações
        totalrecomenda = totalrecomenda+1; % conta as
recomendações do usuário
    end
    aux=0;
    auxPears=0;
    qtd=0;
end
end
y(i,:)=[totalrecomenda]; % total de recomendações de cada usuário
totalrecomenda=0;
%end
end
list_pred= z;
close(h)

%% fim gera as predições pela Rede de Confiança implícita Pearson

%%gera as predições pela confiança implícita Cluster K-means
num_itens=0;
recomenda=1;
[a,b]=size(mat_base);
aux=0;
qtd=1;
y=[0];
totalrecomenda=0;
auxPears=0;
fatorConfianca=0.4;
z=[0];
novoUsuario=0;

[uid, mid, r]=textread('ul.base','%u %u %u %*u'); % tabela que será
comparado
listT=[uid mid r];
clear uid mid r

rnumT=length(listT);
mat_baseT= list2mat(listT);

[uid, mid, r]=textread('confiancascluster.txt','%u %u %u %u %*u'); %
tabela com as confianças implícitas geradas pelo cluster no spss
listT=[uid mid r];
clear uid mid r

[ca,cb]=size(listT);

C=zeros(unum,unum);

for i=1:ca,
    C(listT(i,2),listT(i,3))=(listT(i,4)/100);
end
users_th=1;

```



```

for i=1:a, % usuário alvo da recomendação
    for k=1:b, % itens da base de dados
        if (mat_base(i,k)==0)&&(mat_baseT(i,k)>0)
            for j=1:a, % usuários para comparar
                if (C(i,j)>=0.2)&&(j~=i)&&(mat_base(j,k)~=0)
                    aux = aux + (mat_base(j,k)*C(i,j)); %numerador
                    auxPears = auxPears + C(i,j); % denominador
                    qtd = qtd + 1;
                end
            end
            if (qtd>=users_th)
                z(recomenda,1)=i; % usuário
                z(recomenda,2)=k; % item
                score=(aux/auxPears);

score=(score<=1)+score*((score<5)&(score>1))+5*(score>=5);
                z(recomenda,3)=score; % predição da avaliação
                z(recomenda,4)=mat_baseT(i,k); % avaliação real
                z(recomenda,5)=qtd; % qtd de pessoas que afetaram na
recomendação
                recomenda=recomenda+1; % contagem geral do vetor de
recomendações
                totalrecomenda = totalrecomenda+1; % conta as
recomendações do usuário
            end
            aux=0;
            auxPears=0;
            qtd=0;
        end
    end
    y(i,:)=[totalrecomenda]; % total de recomendações de cada usuário
    totalrecomenda=0;
end
%end
end
list_pred= z;
close(h)

%% fim gera as predições pela confiança implícita Cluster K-means

```

# ANEXO B – CONVITE PARA O EXPERIMENTO

Olá,

Gostaria de convidar você para participar do experimento da minha dissertação.

O objetivo desse experimento é analisar diferentes maneiras de recomendar itens para pessoas. Para isso, nosso protótipo será o ActivUFRJ e os itens serão filmes.

O experimento será em 5 etapas rápidas, divididas semanalmente e não demandarão de muito tempo para realização das mesmas, detalhadas a seguir.

## **Etapa 0: Cadastro e conhecimento da Comunidade Virtual**

**Objetivo:** Entrar no ambiente, realizar o cadastro e navegar livremente.

**Sugestão:** Entre no link <http://activufrj.nce.ufrj.br>, clique em cadastre-se e siga as orientações até finalizar o cadastro. Depois acesse o ambiente e navegue livremente. Para alterar a foto entre no link alterar perfil dentro do ambiente.

**Observação:** Se houver qualquer erro, peço que me comunique.

**Início:** 23/03/2008 – **Final:** 28/03/2008

## **Etapa 1: Avaliação de itens**

**Objetivo:** Cada participante deve avaliar **entre 20 e 40 filmes** da comunidade filmes, sendo o mais honesto possível. Estas avaliações servirão para montar seu perfil e, a partir dele, serão recomendados filmes a você que sejam de seu interesse.

**Sugestão:** Encontre a comunidade filmes pela busca. Em seguida, selecione o filme a ser avaliado e deixe seus comentários.

**Observação:** Seja o mais honesto possível.

**Início:** 23/03/2008 – **Final:** 31/03/2008

## **Etapa 2: Rede de Confiança**

**Objetivo:** Inserir **pelo menos 2 pessoas** na Rede de Confiança.

**Sugestão:** Busque usuários, analise as contribuições do usuário na comunidade (comentários, avaliações, qualidade das avaliações, similaridade a você em relação à área específica "Filmes") e indique seu grau de confiança geral e específico. Note que ao inserir o grau de confiança específico você deve indicar que a área é "filmes".

**Observação:** Confiança não é igual a amigo, mas sim uma pessoa que você confia nos gostos.

**Início:** 31/03/2008 – **Final:** 07/04/2008

## **Etapa 3: Feedback das recomendações método 1**

**Objetivo:** Receber seu retorno em relação às predições realizadas pelo ambiente.

**Sugestão:** Entrar no ambiente, acessar a aba recomendações e concordar ou não com as recomendações realizadas pelo primeiro método. Sempre que discordar da recomendação, faça o ajuste indicando a nota que daria caso tivesse avaliado.

**Início:** 08/04/2008 – **Final:** 14/04/2008

**Etapa 4: Feedback das recomendações método 2**

**Objetivo:** Receber seu retorno em relação às predições realizadas pelo ambiente.

**Sugestão:** Entrar no ambiente, acessar a aba recomendações e concordar ou não com as recomendações realizadas pelo primeiro método. Sempre que discordar da recomendação, faça o ajuste indicando a nota que daria caso tivesse avaliado.

**Início:** 15/04/2008 – **Final:** 21/04/2008

Para acesso ao sistema entre <http://activufrj.nce.ufrj.br>

Qualquer dúvida entre em contato.

**Tenho certeza que seu pequeno esforço agregará um enorme valor para minha dissertação e para o grupo GINAPE.**

Agradeço desde já sua colaboração.

Abraços,  
Leonardo Rosa Zanette  
Mestrando em Informática IM-NCE/UFRJ  
Grupo de Informática Aplicada à Educação (GINAPE)  
tel: (24) 9827-9869  
mail: [leonardorosa@posgrad.nce.ufrj.br](mailto:leonardorosa@posgrad.nce.ufrj.br)

# ANEXO C – QUESTIONÁRIO DO EXPERIMENTO

## a) E-mail enviado aos participantes

Prezado(a),

Gostaria que você dedicasse um tempo para responder este questionário, que tem como objetivo saber sua opinião sobre a utilização do ambiente. As perguntas estão relacionadas aos recursos tecnológicos utilizados, funcionalidades e interface do ambiente, avaliação de artefatos, Rede de Confiança e recomendações recebidas.

Agradeço sua participação no experimento e no preenchimento deste questionário, tenho certeza que sua contribuição tem grande relevância para essa pesquisa e para o grupo GINAPE.

As informações fornecidas serão confidenciais e para uso restrito do pesquisador.

Muito obrigado

**Leonardo Zanette**

## Questionário Sobre o ActivUFRJ

### SOBRE OS RECURSOS TECNOLÓGICOS UTILIZADOS

<p>Na realização do experimento qual foi o sistema operacional utilizado?</p> <p><input type="checkbox"/> Windows    <input type="checkbox"/> Linux <input type="checkbox"/> Outro_____    <input type="checkbox"/> Não sei</p>
<p>Qual foi o navegador web que você utilizou?</p> <p><input type="checkbox"/> Internet Explorer    <input type="checkbox"/> Mozilla Firefox    <input type="checkbox"/> Outro_____    <input type="checkbox"/> Não sei</p>
<p>Qual o tipo de conexão a Internet que você utilizou?</p> <p><input type="checkbox"/> Conexão discada    <input type="checkbox"/> Conexão Banda Larga    <input type="checkbox"/> Outro_____    <input type="checkbox"/> Não sei</p>
<p>Comentários adicionais:</p>

Como você classifica a <b>facilidade de uso do ActivUFRJ</b> quanto :	Totalmente insatisfeito	Parcialmente insatisfeito	Parcialmente satisfeito	Totalmente satisfeito	Não observado
Às tecnologias empregadas no ambiente?					
Às funcionalidades (ex.: perfil, busca, cadastro, etc.) do ambiente?					
À facilidade de navegação entre os recursos disponíveis?					
Ao <i>feedback</i> do ambiente para as ações executadas?					
O uso das ferramentas (ex.: avaliação de artefato, Rede de Confiança, etc) do ambiente?					
O ActivUFRJ como comunidade virtual da UFRJ?					
Comentários adicionais:					

Como você classifica a <b>Interface do ActivUFRJ</b> quanto:	Totalmente insatisfeito	Parcialmente insatisfeito	Parcialmente satisfeito	Totalmente satisfeito	Não observado
Ao grau de satisfação com a interface em geral?					
Ao layout dos menus e ferramentas na tela?					
Ao layout das funcionalidades dentro da página da comunidade?					
Ao layout das funcionalidades dentro da página do artefato?					
Ao layout das funcionalidades dentro da página do usuário?					
Comentários adicionais sobre a <b>Interface do ActivUFRJ</b> :					
Em relação ao instrumento <b>Avaliação de artefatos</b> , como você classifica:	Totalmente insatisfeito	Parcialmente insatisfeito	Parcialmente satisfeito	Totalmente satisfeito	Não observado
A facilidade de inserir a avaliação?					
A estrutura do formulário de avaliação (estrelas e comentários)?					
A visualização das avaliações feitas por outros usuários na página do artefato?					

A utilidade do instrumento como um todo?					
Comentários adicionais sobre <b>Avaliação de artefatos</b> :					

Como você classifica a <b>Rede de Confiança</b> quanto:	Totalmente insatisfeito	Parcialmente insatisfeito	Parcialmente satisfeito	Totalmente satisfeito	Não observado
À facilidade de encontrar pessoas para adicionar na Rede de Confiança?					
À facilidade em adicionar pessoas em sua Rede de Confiança?					
À estrutura do formulário para adicionar pessoas na Rede de Confiança?					
À possibilidade de adicionar "confiança geral" para uma pessoa?					
À possibilidade de adicionar confianças contextualizadas (Área de interesse)?					
As opções do quanto a pessoa é confiável: nada, pouco, médio e muito?					
À visualização da sua Rede de Confiança?					
À sua confiança na Rede de Confiança?					
Comentários adicionais <b>Rede de Confiança</b> :					

Em relação às <b>Recomendações recebidas</b> , como você classifica:	Totalmente insatisfeito	Parcialmente insatisfeito	Parcialmente satisfeito	Totalmente satisfeito	Não observado
A quantidade de recomendações recebidas?					
A qualidade das recomendações recebidas?					
A ordem das recomendações recebidas?					
O recebimento de recomendações com predição baixa?					
As recomendações pela Rede de Confiança?					
As recomendações pela similaridade?					

A sua confiança nas recomendações recebidas?					
Comentários adicionais sobre as <b>Recomendações recebidas</b> :					


### RELATÓRIO DE *BUGS*

Comentários adicionais:
-------------------------


### SUGESTÕES E CRÍTICAS

Comentários adicionais:
-------------------------


### b) Respostas dos questionários




Conforme o gráfico acima, o Sistema Operacional utilizado por todos os usuários foi o Windows.




Conforme o gráfico acima, o Navegador Web utilizado pelos usuários foi o Internet Explorer e o Mozilla Firefox, em mesma proporção.



Conforme o gráfico acima, a Conexão de Internet utilizada foi de Banda Larga em grande maioria, com apenas 2 usuários utilizando outro tipo de conexão.




Conforme o gráfico acima, 63% dos usuários ficaram totalmente satisfeitos com a interface em geral, 31% ficaram parcialmente satisfeitos e apenas 6% ficaram parcialmente insatisfeitos, não havendo ninguém totalmente insatisfeito.




Conforme gráfico acima, todos ficaram parcialmente satisfeitos ou totalmente satisfeitos quanto às funcionalidades do ambiente.







Conforme gráfico acima, a maioria dos usuários ficaram parcialmente satisfeitos quanto à facilidade de navegação entre os recursos disponíveis, com uma grande parte de usuários totalmente satisfeitos e uma pequena parte, parcialmente insatisfeito.




Conforme gráfico acima, os usuários ficaram parcialmente satisfeitos ou totalmente satisfeitos quanto ao *feedback* do ambiente para as ações executadas.




Conforme gráfico acima, a maioria dos usuários ficaram totalmente satisfeitos quanto ao uso das ferramentas, uma parte ficou parcialmente satisfeito.




Conforme gráfico acima, 63% dos usuários ficaram totalmente satisfeitos quanto a interface em geral, e 31% ficaram parcialmente satisfeito e 6% ficaram parcialmente insatisfeito.




Conforme gráfico acima, 56% dos usuários ficaram totalmente satisfeitos quanto ao *layout* dos menus e ferramentas na tela, 38% ficou parcialmente satisfeito e 6% ficaram parcialmente insatisfeitos.




Conforme gráfico acima, 63% dos usuários ficaram parcialmente satisfeitos quanto ao *layout* das funcionalidades dentro da página da comunidade e os outros 38% ficaram totalmente satisfeito.




Conforme gráfico acima, 56% dos usuários ficaram parcialmente satisfeitos quanto ao *layout* das funcionalidades dentro da página do artefato e 44% ficaram totalmente satisfeito.




Conforme gráfico acima, 56% dos usuários ficaram parcialmente satisfeitos quanto ao *layout* das funcionalidades dentro da página do usuário e 44% ficaram totalmente satisfeito.




Conforme gráfico acima, 69% dos usuários ficaram totalmente satisfeitos quanto à facilidade de inserir a avaliação e 31% ficaram parcialmente satisfeito.




Conforme gráfico acima, 69% dos usuários ficaram totalmente satisfeitos quanto a estrutura do formulário de avaliação e 25% ficaram parcialmente satisfeitos.




Conforme gráfico acima, 63% dos usuários ficaram totalmente satisfeitos quanto a visualização das avaliações feitas por outros usuários na página do artefato, 25% ficaram parcialmente satisfeitos.




Conforme gráfico acima, 75% dos usuários ficaram totalmente satisfeitos quanto à utilidade do instrumento como um todo e 19% ficaram parcialmente satisfeito.




Conforme gráfico acima, 50% dos usuários ficaram parcialmente satisfeitos quanto à facilidade de encontrar pessoas para adicionar na Rede de Confiança, 31% ficaram totalmente satisfeito e 13% ficaram parcialmente insatisfeitos.




Conforme gráfico acima, 69% dos usuários ficaram totalmente satisfeitos quanto à facilidade em adicionar pessoas em sua Rede de Confiança e 25% ficaram parcialmente satisfeito.




Conforme gráfico acima, 50% dos usuários ficaram totalmente satisfeitos quanto à estrutura do formulário para adicionar pessoas na Rede de Confiança, 38% ficaram parcialmente satisfeitos e apenas 6% em cada ficou parcialmente insatisfeito ou não observou o item.




Conforme o gráfico acima, 63% dos usuários ficaram totalmente satisfeitos quanto à possibilidade de adicionar “confiança geral” para uma pessoa e 25% ficaram parcialmente satisfeitos.




Conforme gráfico acima, 75% dos usuários ficaram totalmente satisfeitos quanto à possibilidade de adicionar confianças contextualizadas e apenas 13% em cada, ficou ou parcialmente satisfeito ou não observou o item.




Conforme gráfico acima, 56% dos usuários ficaram totalmente satisfeitos quanto às opções do quanto a pessoa é confiável, 31% ficou parcialmente satisfeito e 13% não observou esse item.




Conforme gráfico acima, 75% dos usuários ficaram totalmente satisfeitos quanto à visualização da sua Rede de Confiança, 19% ficou parcialmente satisfeito e apenas 6% não observou o item.




Conforme gráfico acima, 63% dos usuários ficaram totalmente satisfeitos quanto à sua confiança na Rede de Confiança, 19% ficou parcialmente satisfeito, 13% não observou e apenas 6% ficou parcialmente insatisfeito.



Conforme gráfico acima, 47% dos usuários ficaram ou totalmente satisfeitos ou parcialmente satisfeitos quanto a quantidade de recomendações recebidas, o que representa um bom índice e apenas 7% não observou o item.




Conforme gráfico acima, 47% dos usuários ficaram totalmente satisfeitos quanto a qualidade das recomendações recebidas e 40% ficou parcialmente satisfeitos enquanto 7% ficou parcialmente insatisfeito ou não observou o item.







Conforme o gráfico acima, 47% dos usuários ficaram parcialmente satisfeitos quanto a ordem das recomendações recebidas, 33% ficou totalmente satisfeito, 13% não observou e apenas 7% ficou parcialmente insatisfeito.




Conforme gráfico acima, 40% dos usuários ficaram parcialmente satisfeitos quanto ao recebimento de recomendações com predição baixa, 27% ficou totalmente satisfeito ou não observou e apenas 7% ficou parcialmente insatisfeito.



Conforme gráfico acima, 33% dos usuários ficaram ou totalmente satisfeitos ou parcialmente satisfeitos quanto as recomendações pela Rede de Confiança, 27% não observou o item e apenas 7% ficou parcialmente insatisfeito.



Conforme gráfico acima, 47% dos usuários ficaram parcialmente satisfeitos quanto às recomendações pela similaridade, 33% não observou, 13% ficou totalmente satisfeitos e apenas 7% ficou parcialmente insatisfeito.



Conforme gráfico acima, 53% dos usuários ficaram parcialmente satisfeitos, 33% ficou totalmente satisfeito, e 7% cada ficou parcialmente insatisfeito ou não observou.