



USUÁRIO MAIS REPRESENTATIVO: UMA ESTRATÉGIA DE AGREGAÇÃO DE PREFERÊNCIAS PARA RECOMENDAÇÃO EM GRUPO

Pedro dos Santos Rougemont

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia de Sistemas e Computação, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia de Sistemas e Computação.

Orientador: Geraldo Zimbrão da Silva

Rio de Janeiro
Setembro de 2013

USUÁRIO MAIS REPRESENTATIVO: UMA ESTRATÉGIA DE AGREGAÇÃO
DE PREFERÊNCIAS PARA RECOMENDAÇÃO EM GRUPO

Pedro dos Santos Rougemont

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE) DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM CIÊNCIAS EM ENGENHARIA DE SISTEMAS E COMPUTAÇÃO.

Examinada por:

Prof.^o Geraldo Zimbrão da Silva, D.Sc.

Prof.^a Geraldo Bonorino Xexéo, D.Sc.

Prof. Alexandre Plastino de Carvalho, D.Sc.

RIO DE JANEIRO, RJ – BRASIL

SETEMBRO DE 2013

Rougemont, Pedro dos Santos

Usuário Mais Representativo: uma estratégia de agregação de preferências para recomendação em grupo/
Pedro dos Santos Rougemont. – Rio de Janeiro: UFRJ/COPPE, 2013.

XIV, 106 p.: il.; 29,7 cm.

Orientador: Geraldo Zimbrão da Silva

Dissertação (mestrado) – UFRJ/ COPPE/ Programa de Engenharia de Sistemas e Computação, 2013.

Referencias Bibliográficas: p. 103-106.

1. Sistemas de Recomendação. 2. Sistemas de Recomendação para Grupos. 3. Teoria da Escolha Social. I. Silva, Geraldo Zimbrão. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia de Sistemas e Computação. III Título.

À família, filhos e amigos.

AGRADECIMENTOS

Agradeço a todos os envolvidos direta e indiretamente no desenvolvimento deste trabalho. Primeiramente gostaria de agradecer ao Programa de Engenharia de Sistemas e Computação da COPPE/UFRJ, por ter me acolhido como aluno de mestrado.

Especial gratidão a meu orientador Prof. Dr. Geraldo Zimbrão, e meu coorientador não oficial, agora doutor, Dr. Carlos Eduardo Mello. Durante o tempo do mestrado os senhores me acompanharam na concepção de ideias, momentos de tomada de decisão e auxiliaram em aspectos críticos para o sucesso deste trabalho. Além de professores, considero-os também como amigos.

Agradeço aos professores Prof. Dr. Geraldo Xexéo e Prof. Dr. Alexandre Plastino, em se disponibilizarem para integrar minha banca de mestrado. Ao professor Xexéo, devo gratidão também a sua contribuição na divulgação do sistema Filmes em Grupo, utilizado neste trabalho.

Agradeço a todos meus companheiros de pesquisa, seja pelos repentinos *brainstorms*, que serviram para esclarecer muitas ideias, seja pelos momentos de descontração. Ao Filipe Braida e Marden Pasinato, reservo aqui imensa gratidão pelo apoio de vocês, que foi de fundamental importância para conclusão desta dissertação. Também reservo diversos agradecimentos às contribuições de Fellipe Duarte, Luis Orleans e Bruno Osiek.

Agradeço ao apoio de minha companheira, Bianca Warlez, por sua compreensão e por tudo que fez por mim, você é meu chão. Agradeço minha filha, Sofia, e meu enteado, Luar, por iluminarem meus finais de semana, vocês tem um grande espaço na minha vida.

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

USUÁRIO MAIS REPRESENTATIVO: UMA ESTRATÉGIA DE AGREGAÇÃO DE PREFERÊNCIAS PARA RECOMENDAÇÃO EM GRUPO

Pedro dos Santos Rougemont

Setembro/2013

Orientador: Geraldo Zimbrão da Silva

Programa: Engenharia de Sistemas e Computação

Este trabalho propõe uma nova metodologia para o problema de Recomendação em Grupo. Nesta abordagem, escolhemos o Usuário Mais Representativo (MRU) como o usuário medóide do grupo em uma projeção do espaço de usuários, e assim, geramos recomendações baseadas em suas preferências. Nos experimentos, avaliamos nossa proposta junto a outras estratégias de Recomendação em Grupo, escolhendo para isso duas medidas de referência da área. Discutimos também propriedades presentes em nossa estratégia que lhe garantem robustez a problemas inerentes da interação em grupos de usuários. Além disso, desenvolvemos o sistema Filmes em Grupo, no intuito de obter um conjunto de dados que melhor se adequasse aos experimentos da área.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

**MOST REPRESENTATIVE USER: A PREFERENCE AGGREGATION STRATEGY FOR
GROUP RECOMMENDATION**

Pedro dos Santos Rougemont

September/2013

Advisor: Geraldo Zimbrão da Silva

Department: Computer Science Engineering

This work proposes a new methodology for the Group Recommendation problem. In this approach we choose the Most Representative User (MRU) as the group medoid in a user space projection, and then generate recommendation based on his preferences. In the experiments, we evaluate our proposal along with other Group Recommendation strategies, taking two different measures from the area. We also discuss about properties shown by our strategy that provides robustness to problems inherent to interactions in group of users. Besides that, we developed the system Filmes em Grupo in order to obtain a dataset that best suited experiments in the area.

ÍNDICE

Capítulo 1 – Introdução	1
1.1 – Motivação	1
1.2 – Objetivo	2
1.3 – Proposta	3
1.4 – Organização	3
Capítulo 2 – Fundamentação Teórica	4
2.1 – Teoria da Escolha Social	4
2.1.1 – Formalização e propriedades	4
2.1.2 – Principais descobertas	7
2.1.3 – Sistemas de votação propostos	8
2.1.4 – Medidas	12
2.2 – Sistemas de Recomendação	15
2.2.1 – Sistemas de Recomendação Individual	16
2.2.2 – Sistemas de Recomendação para Grupos	31
Capítulo 3 – Proposta de estratégia: Usuário Mais Representativo	51
3.1 – Introdução	51
3.2 – Formalização matemática do problema	51
3.3 – Estratégia proposta	53
3.4 – Propriedades da Proposta	55
3.4.1 – Conversão de estratégias de agregação para funções de bem-estar social	57
3.4.2 – Definição formal das propriedades e aderência das estratégias	59
3.5 – Vantagens e limitações das dimensões de Recomendação em Grupo	66
3.5.1 – Dinamicidade dos grupos	66
3.5.2 – Conhecimento Mútuo	67
3.5.3 – Tamanho do Grupo	67
3.5.4 – Frequência de atualizações das preferências	68
Capítulo 4 – Coleta de preferências: Filmes em Grupo	69
4.1.1 – Objetivos dos experimentos	69
4.1.2 – Etapa um: Coleta de Preferências	70
4.1.3 – Etapa dois: Recomendação em grupo e resolução de conflitos	75
4.1.4 – Etapa três: Coleta direcionada para Recomendação em Grupo	86

Capítulo 5 – Experimentos	91
5.1 – Conjuntos de dados considerados	91
5.2 – Formatação dos experimentos	92
5.3 – Análise dos Resultados	94
5.3.1 – Filmes em Grupo	95
5.3.2 – <i>Movielens</i> 100K	98
5.3.2 – <i>Movielens</i> 100K HV	99
Capítulo 6 – Conclusões	101
6.1 – Considerações acerca do trabalho	101
6.2 – Contribuições	101
6.3 – Limitações e trabalhos futuros	102
Referências Bibliográficas	103

LISTAGEM DE FIGURAS

Figura 1 – Processo de recomendação em Sistemas de Recomendação Individual Baseados em Dados Demográficos	18
Figura 2 – Processo de recomendação em Sistemas de Recomendação Individual Baseados em Conteúdo	19
Figura 3 – Rede bayesiana ilustrativa para Filtro Colaborativo	26
Figura 4 – Dimensões da recomendação em grupo	39
Figura 5 – Etapas da recomendação para grupos	40
Figura 6 – Contraexemplo para independência das alternativas irrelevantes na estratégia Média Simples	63
Figura 7 – Contraexemplo para independência das alternativas irrelevantes na estratégia Miséria Mínima	63
Figura 8 – Contraexemplo para independência das alternativas irrelevantes na estratégia Ditatorial (por sorteio aleatório)	64
Figura 9 – Contraexemplo para independência das alternativas irrelevantes na estratégia Usuário Mais Representativo	64
Figura 10 – Critério de seleção do MRU para diferentes funções de distância	67
Figura 11 – Imagem da tela de boas vindas do Filmes em Grupo	71
Figura 12 – Tela para cadastro de novo usuário do Filmes em Grupo	72
Figura 13 – Tela de captura de preferências da primeira etapa do Filmes em Grupo	73
Figura 14 – Tela inicial da segunda etapa do Filmes em Grupo	76
Figura 15 – Instruções da segunda etapa do Filmes em Grupo	77
Figura 16 – Tela para aprovação dos itens recomendados ao grupo	78
Figura 17 – Contagem de recomendações aprovadas por membros do grupo	79
Figura 18 – Instruções para resolução de conflitos	80
Figura 19 – Tela de resolução de conflitos	81

Figura 20 – Boas vindas da terceira etapa do Filmes em Grupo	87
Figura 21 – Instruções da terceira etapa do Filmes em Grupo	88
Figura 22 – Tela de explicitação de preferências da terceira etapa	89
Figura 23 – Representação das iterações do experimento para validação da proposta	93

LISTAGEM DE TABELAS

Tabela 1 – Preferências para conjuntos de eleitores no exemplo de maioria simples	9
Tabela 2 – Preferências para eleitores no exemplo de voto sequencial	10
Tabela 3 – Preferências de eleitores no exemplo do Método de Borda	12
Tabela 4 – Cruzamento entre pares de Sistema de Recomendação Individual e número de publicações identificadas em (BURKE, 2002)	29
Tabela 5 – Índices da primeira etapa	74
Tabela 6 – Números da segunda etapa do Filmes em Grupo	82
Tabela 7 – Números da Etapa 3 do Filmes em Grupo	90
Tabela 8 – Resultados da medida nDCG para o conjunto de dados Filmes em Grupo	95
Tabela 9 – Resultados da medida coeficiente Tau de Kendall para o conjunto de dados Filmes em grupo	96
Tabela 10 – Resultados da medida nDGC para o conjunto de dados <i>Movielens</i> 100K	98
Tabela 11 – Resultados da medida coeficiente Tau de Kendall para o conjunto de dados <i>Movielens</i> 100K	98
Tabela 12 – Resultados da medida nDGC para o conjunto de dados <i>Movielens</i> 100K composta por itens c/ alta variância	99
Tabela 13 – Resultados da medida coeficiente Tau de Kendall para o conjunto de dados <i>Movielens</i> 100K composta por itens c/ alta variância	100

LISTAGEM DE EQUAÇÕES

Equação 1 – <i>Spearman's Footrule</i>	13
Equação 2 – Coeficiente de correlação de Spearman.....	13
Equação 3 – Distância de Hamming.....	13
Equação 4 – Coeficiente de correlação Tau de Kendall.....	14
Equação 5 – Probabilidade de M_i assumir a_i	17
Equação 6 – Probabilidade de M_i assumir a_i condicionado a M_j assumir a_j	17
Equação 7 – Conjunto de recomendação para sistemas baseados em utilidade.....	17
Equação 8 – Itens recomendados pelo Sistema de Recomendação Baseado em Memória com similaridade usuário-usuário.....	21
Equação 9 – Função de predição das avaliações em Sistema de Recomendação Baseado em Memória com similaridade usuário-usuário	22
Equação 10 – Correlação por cosseno	23
Equação 11 – Correlação de Pearson	23
Equação 12 – Função de predição das avaliações em Sistema de Recomendação Baseado em Memória com similaridade item-item	24
Equação 13 – Fórmula ingênua de Bayes para previsão da avaliação $r(i)$	26
Equação 14 – Fórmula para decomposição SVD da matriz A	27
Equação 15 – Média sem Miséria em <i>MusicFX</i>	45
Equação 16 – Fórmula para relevância com fator de dissimilaridade.....	45
Equação 17 – Discordância par a par	46
Equação 18 – Variância da Discordância.....	46
Equação 19 – Fórmula de nDCG.....	50
Equação 20 – Fórmula de DCG.....	50
Equação 21 – Regra de formação dos elementos de L_{max}	52

Equação 22 – Função de preferência do grupo para o método Usuário Mais Representativo .	54
Equação 23 – Distância euclidiana para dois vetores de preferências	54
Equação 24 – Distância Manhattan para dois vetores de preferências.....	54
Equação 25 – Matrizes na Decomposição em Valores Singulares (SVD)	55
Equação 26 – Tradução de preferências de usuário expressa em vetor de avaliações para ordenação fraca.....	56
Equação 27 – Tradução de preferência de usuário expressa em ordenação fraca para vetor de avaliações.....	56

Capítulo 1 – Introdução

1.1 – Motivação

A ascensão da computação e do uso da internet como meio de comunicação nas últimas duas décadas levou a diversas transformações em nosso cotidiano. Passamos a interagir, produzir, compartilhar e armazenar informações em volume e velocidade nunca antes vistos. Hoje formamos uma cadeia complexa na qual estamos conectados, tendo acesso a uma quantidade interminável de conteúdo, que ultrapassa a capacidade humana de digerir informação.

A exposição a esta grande quantidade de informação impulsionou inicialmente o desenvolvimento de ferramentas que pudessem dar suporte para a busca, filtragem e organização de conteúdo, popularizando-se assim nos anos 90 as ferramentas de busca, como Cadê, Altavista e Yahoo (HOCK, 2001).

Em 1995, as vendas por meio da internet, ou e-commerce, começam a deslanchar nos EUA com o surgimento da Amazon.com, uma das pioneiras em vendas online. Neste modelo, a seleção de produtos e posterior compra são realizadas inteiramente online através de vitrines virtuais. Esta modalidade de comércio hoje corresponde à maior parte do faturamento de muitas empresas, já existindo lojas que funcionem completamente no modelo virtual.

O amadurecimento da web, e a mudança de tendências, batizada por especialistas de “Web 2.0” sugere novas formas de interação entre websites e usuários. Um destes novos conceitos é a chamada personalização para web, em que cada usuário usufrui de uma experiência diferenciada de navegação. A personalização é definida em linhas gerais por (MITTAL & LASSAR, 1996) como a adaptação e adequação dos serviços oferecidos a alguém, conforme suas necessidades, preferências e vontades.

Uma das grandes bandeiras da “Web 2.0” é a colaboração, através da qual, usuários são capazes de colocar seu próprio conteúdo na web. A função que até então se concentrava nas mãos de um único mantenedor por website, chamado à época *webmaster*, passa a poder ser exercida por qualquer usuário. Esta nova dinâmica incentivou o surgimento de

comunidades virtuais em torno destas plataformas, nas quais seus participantes contribuem coletivamente com seu conteúdo.

Este aumento da troca de informações pela internet ao longo das últimas décadas abriu caminho para sistemas que direcionassem conteúdo, não só individualmente, mas também para grupos de pessoas. Sistemas de Recomendação Individual surgiram ainda na década de 80, como sistemas de filtragem para e-mails, até que na década seguinte se consolidaram na área de e-commerce (MALONE *et al.*, 1987).

O problema da Recomendação em Grupo, que consiste na recomendação de itens para grupos de pessoas, respeitando suas particularidades individuais, começou a ser estudado como área após a publicação do trabalho de (MCCARTHY & ANAGNOST, 1998). Em seu trabalho, eles desenvolveram um sistema de *Jukebox* automático para uma academia de ginástica, no qual utilizaram as preferências dos usuários presentes em determinado momento para seleção dos gêneros musicais que tocariam no ambiente.

As contribuições seguintes vieram com o grupo de pesquisa *GroupLens*, com sua extensão ao sistema de Recomendação Individual *MovieLens* (batizado por *PolyLens*) (O'CONNOR *et al.*, 2002), que utilizou agrupamento de usuários para direcionar recomendação de filmes.

Ao mesmo tempo, Masthoff desenvolveu experimentos práticos com voluntários em (MASTHOFF, 2002), no intuito de mapear o comportamento humano em grupo. Seu objetivo foi avaliar o mecanismo de tomada de decisão para escolha de um número limitado de itens por determinado grupo de participantes. Seu paralelo com a Teoria da Escolha Social e a consolidação destas ideias hoje constitui a área de Recomendação em Grupos.

1.2 – Objetivo

O objetivo deste trabalho é o de propor uma nova abordagem para a Recomendação em Grupo, obtendo resultados que atendam ao máximo a satisfação de usuários de sistemas desta categoria. Para isso, propomos uma aproximação para o problema capaz de exprimir as preferências do grupo de uma forma não explorada até o momento. Além disso, pretendemos contribuir com a comunidade acadêmica, através da disponibilização de um conjunto de dados

próprio para experimentos da área, obtido através do desenvolvimento de um sistema de coleta de dados.

1.3 – Proposta

No decorrer dos estudos relacionados à recomendação em grupo, optamos por centrar esforços em aprimoramentos à etapa de “agregação de preferências”, tratada no capítulo dois. O estágio em que se encontra a pesquisa fornece perspectiva para contribuição a esta etapa de forma isolada, abstraindo-se questões de cunho comportamental como humor, contexto, relações pessoais, etc.

Nossa proposta parte na tentativa de generalizar a opinião do grupo em um usuário mais representativo, para o qual o sistema possa gerar uma recomendação mais efetiva. O pressuposto é de que seja possível estabelecer um usuário medóide, de forma a simular o comportamento do grupo como um todo.

1.4 – Organização

O trabalho se resume em seis capítulos. O segundo capítulo trará a revisão de literatura de recomendação em grupo, além de uma passagem geral sobre Teoria da Escolha Social e Sistemas de Recomendação Individual. No capítulo três será exposta a proposta detalhada da dissertação. No capítulo quatro trataremos de nossa iniciativa para a coleta de dados e realização de experimentos para grupos, o projeto “Filmes em Grupo”. No cinco, os resultados de testes feitos com a estratégia proposta no trabalho em cima de bases de dados de recomendação. No capítulo seis serão feitas as conclusões finais e tratadas as perspectivas futuras para a pesquisa.

Capítulo 2 – Fundamentação Teórica

Neste capítulo apresentaremos a fundamentação teórica necessária para compreender a pesquisa em Recomendação em Grupo. Os trabalhos mais recentes estão fortemente baseados em conceitos advindos da Teoria da Escolha Social e de Sistemas de Recomendação. Tais conceitos serão detalhados a seguir.

2.1 – Teoria da Escolha Social

A Teoria da Escolha Social possui dois principais objetivos: *i*) encontrar um sistema de votação robusto e adequado e *ii*) encontrar uma medida para o bem-estar social agregado (ELSTER & HYLLAND, 1989). As duas questões podem ser resumidas em um mesmo problema: encontrar uma função que transforme diversas listas, contendo as preferências individuais, em uma única lista, contendo a preferência comum para o grupo, que obedece a certas propriedades de justiça distributiva (DEUTSCH, 1985).

Esta teoria possui conexões próximas com Teoria de Jogos, cooperativos e não cooperativos, particularmente no que se refere ao problema da barganha com n -pessoas, onde o objetivo é derivar um resultado coletivo a partir de preferências individuais (HARSANYI, 1958). Em ambos os casos, o ótimo de Pareto é uma restrição, no entanto teorias de barganha impõem maior complexidade ao problema e possui enfoque no poder de barganha dos participantes, maximizando o que cada parte pode obter na falta de acordo. Não existe conceito semelhante em Teoria da Escolha Social (ELSTER & HYLLAND, 1989).

2.1.1 – Formalização e propriedades

O principal foco desta pesquisa é estudar os tipos de sistemas de votação onde se deseja agregar n ($n \geq 3$) listas de preferências fracamente ordenadas, ou seja, listas onde se admite empate entre duas ou mais opções. O resultado é uma lista resultante, também fracamente ordenada, que possui certas propriedades de aceitação social. Convém então a seguinte formalização:

Seja $N = \{1, 2, \dots, n\}$ o conjunto de eleitores e A o conjunto de opções. Suponha que o eleitor $x \in N$ expresse suas preferências através de uma lista fracamente ordenada $R_x \in W(A)$, onde $W(A)$ é o conjunto de todas as possíveis listas fracamente ordenadas de A .

Queremos encontrar uma função de agregação F que seja “democrática” para este cenário. Ou seja, esta função deve ter como resultado uma lista, fracamente ordenada, de preferência coletiva que reflète as preferências individuais (BOUYSSOU *et al.*, 2010).

Uma função F é considerada como mais ou menos democrática na medida em que é capaz de atender em maior ou menor número as seguintes propriedades:

- *Universalidade*: qualquer ordenação de escolhas é admissível;
- *Transitividade*: seu resultado deve sempre ser uma ordenação completa dos elementos de A , possivelmente com empates;
- *Unanimidade*: o resultado do método de agregação não deve contradizer ordenações unânimes. Em outras palavras, se para todas as listas de preferências individuais, um item precede outro, esta precedência também deve se verificar na lista coletiva resultante;
- *Independência das alternativas irrelevantes*: a posição relativa entre duas opções na lista resultante depende apenas de suas posições relativas nas ordenações individuais. Isto poderia ser dividido em dois requisitos: *i*) somente a precedência, e não a distância, entre as opções deve ser considerada e *ii*) esta precedência não deve depender da existência de uma terceira opção;
- *Não ditatoriedade*: não deve haver qualquer restrição às soluções admissíveis em virtude de algum conflito de preferências entre um dos eleitores e o resultado final. Em caso de favorecimento de um subgrupo de usuários, a função é dita oligárquica.
- *Neutralidade*: para a construção da lista, considerar somente a precedência entre as opções. Todas as alternativas devem ser tratadas da mesma maneira, sem critérios de desempate, uso de informações de contexto, etc..
- *Anonimato*: análogo à neutralidade para os eleitores. Nenhum eleitor deve ser favorecido por F .
- *Monotonicidade*: dadas as preferências dos eleitores, se as alternativas a e b estão empatadas, basta que se inverta a precedência de apenas um dos eleitores para que o empate seja desfeito.

- *Não manipulabilidade*: a exposição não sincera das preferências de um eleitor não deve favorecer suas escolhas sinceras. Uma consequência da ausência desta propriedade e da monotonicidade é o desencorajamento da participação, onde um eleitor pode se beneficiar por se abster.
- *Consistência*: se separarmos os eleitores em subgrupos, aplicarmos F a cada um destes e obtivermos um conjunto de ordenações de precedências comuns, este conjunto também deve se verificar na aplicação de F a todos os eleitores.
- *Boa-fé*: se houver apenas um único eleitor, suas escolhas devem igualar suas preferências.
- *Cancelamento*: dado que o número de precedentes seja o mesmo para todas as alternativas (empate total), então todas as alternativas devem ser escolhidas pela função.
- *Princípio de Condorcet*: candidato A precede o candidato B se o número de eleitores que escolhem A precedendo B é maior do que os que escolhem B precedendo A . Um ganhador de Condorcet é aquele que apresenta esta propriedade para todos os demais candidatos par a par.
- *Princípio fraco de Condorcet*: se um candidato não perde para qualquer outro por maioria simples, ele deve preceder os demais (admite-se empate).

As propriedades sugeridas na literatura não se limitam às supracitadas. Todas essas noções buscam avaliar de maneira qualitativa as funções de agregação e possuem definição correspondente na forma axiomática. Para verificar se determinada estratégia de agregação atende a cada uma destas propriedades, basta provar estes axiomas a partir de sua definição formal, como mostra (BOUYSSOU *et al.*, 2010).

Além destas, existem também propriedades quantitativas referentes aos resultados gerados por cada estratégia. Para este tipo de avaliação, métricas foram desenvolvidas e algumas destas são apresentadas mais adiante.

2.1.2 – Principais descobertas

Na literatura, vários teoremas foram formulados provando que certas combinações destas propriedades são impossíveis de se obter de maneira simultânea. O Teorema de Arrow ou Teorema da Impossibilidade de Arrow é, provavelmente, o mais importante tendo motivado diversos ensaios que se seguiram. Ele estabelece que:

“Na existência de pelo menos três alternativas para as quais membros de uma sociedade tenham a liberdade de ordená-las de qualquer maneira [...] os únicos métodos de escolha social satisfatórios e definidos para todo o conjunto de ordenações possível são impositivos ou ditatoriais” (ARROW, 1950).

Adiante ele se refere ao significado de satisfatório como o de um método que “não reflete negativamente os desejos individuais e cuja ordenação resultante possua as propriedades usuais da racionalidade”. Estas propriedades, descritas por Arrow, aparecem claramente formuladas na seguinte releitura do teorema:

“Nenhum método de agregação pode simultaneamente satisfazer universalidade, transitividade, unanimidade, independência das alternativas irrelevantes e ser não ditatorial” (BOUYSSOU et al., 2010)

Este teorema é central na Teoria de Escolha Social, uma vez que a inexistência de uma estratégia ideal permite um leque infundável de proposições, cada qual com suas vantagens e desvantagens. Outros teoremas formulados na área estabelecem também resultados de impossibilidade, sendo os mais importantes apresentados a seguir.

O Teorema de Gibbard-Satterthwaite diz que não há método de agregação que verifique universalidade, não manipulabilidade e não ditatoriedade, para a escolha de uma única opção dentre pelo menos três candidatos (GIBBARD, 1973, SATTERTHWAITE, 1975).

O Teorema de Sen, ou Paradoxo do Liberal Paretiano, declara que não há como conciliar o critério de ótimo de Pareto (universalidade e unanimidade) com um princípio mínimo de liberdade individual (SEN, 1970).

Ambos os resultados possuem implicações econômicas e sociais, que não serão vistos em profundidade aqui, mas que fornecem fortes restrições para os horizontes que as estratégias de agregação almejam alcançar.

2.1.3 – Sistemas de votação propostos

Como já tratado, uma estratégia que produza resultados democráticos deve ser capaz de considerar pontos de vista conflituosos de maneira não tendenciosa, ou seja, atendendo na medida do possível as propriedades descritas em 2.1.1. A Teoria da Escolha Social dá especial atenção a algumas destas estratégias e estuda suas propriedades, permitindo assim uma comparação e ponderação de prós e contras das mesmas.

Os sistemas de votação podem ser divididos em uninominais ou preferenciais, no que tange a forma como o eleitor elicit suas preferências. Em sistemas uninominais, somente um candidato é escolhido pelo eleitor, enquanto que, nos preferenciais, ordenações totais (sem empates) dos candidatos são definidas pelos eleitores.

2.1.3.1 – Sistemas uninominais

Trata-se de sistemas em que apenas um candidato é escolhido por cada eleitor. Um caso icônico deste tipo de sistema é a escolha de representantes de estado em repúblicas democráticas. Alguns exemplos desta categoria de sistema são ilustrados a seguir.

2.1.3.1.1 – Regra da maioria

Sendo o método de agregação mais popular, a regra da maioria pode ser definida por: candidato A ganha de candidato B se a maioria simples dos eleitores preferirem A a B . Esta regra, apesar de apresentar uma noção intuitiva de justiça, pode demonstrar características negativas, tal qual o problema conhecido como ditadura da maioria.

A ditadura da maioria diz respeito ao cenário em que um candidato é eleito por maioria absoluta. No entanto, o candidato escolhido se mostra como um dos piores candidatos para os demais eleitores entre outras opções de maior aceitação geral. Além disso, é admissível por esta estratégia o cenário em que um candidato consegue se eleger por maioria simples, apesar de perder por maioria absoluta. Veja a Tabela 1:

Tabela 1 – Preferências para conjuntos de eleitores no exemplo de maioria simples

Eleitores\Preferências	Opção 1	Opção 2	Opção 3
4 eleitores	A	B	C
2 eleitores	B	C	A
3 eleitores	C	A	B

Por esta regra, o candidato *A* seria eleito com quatro votos, apesar de *C* preceder a *A* para maioria absoluta dos eleitores. Em outras palavras, esta estratégia não é aderente ao princípio de Condorcet.

Sistemas uninominais que funcionam com a estratégia de agregação de maioria simples são chamados de sistemas de votação plural.

2.1.3.1.2 – Dois turnos

Exemplificando, *A* ganha de candidato *B* se a maioria absoluta dos eleitores preferirem *A* a *B*. Dado que um candidato não obtenha maioria absoluta em primeiro turno, os dois candidatos mais votados são conduzidos ao desempate em um segundo turno.

Apesar de a medida parecer atenuar os problemas relatados no caso anterior, ela falha em impedir que um candidato que constituiria maioria absoluta em uma disputa dois a dois participe do segundo turno e, portanto, não adere também ao princípio de Condorcet. Além disso, este tipo de sistema não atende a não manipulabilidade, monotonicidade e estimula a não participação, todas as propriedades demonstradas em (BOUYSSOU *et al.*, 2010).

2.1.3.1.3 – Voto sequencial

Trata-se do conceito de eliminatórias, muito comum em jogos esportivos. Partindo do princípio que sistemas de maioria são bons quando se têm somente dois candidatos, sorteiam-se os candidatos dois a dois para eliminatórias. Conforme o candidato vence um duelo, ele é encaminhado para disputar o duelo com outro vencedor (ou contra um candidato que ainda não competiu, em caso de número ímpar de opções), e assim sucessivamente.

Este tipo de sistema não atende a propriedade da neutralidade, pois a ordem em que um candidato é sorteado interfere diretamente em sua chance de vitória, problema também conhecido com influência da agenda. Veja o simples exemplo a seguir:

Tabela 2 – Preferências para eleitores no exemplo de voto sequencial

Eleitores\Preferências	Opção 1	Opção 2	Opção 3
Eleitor 1	A	B	C
Eleitor 2	B	C	A
Eleitor 3	C	A	B

Para o sorteio *A* e *B*, depois *C*, teremos:

- Primeira rodada: *A* precede *B* em 2, *B* precede *A* em 1, logo *A* vence;
- Segunda rodada: *A* precede *C* em 1, *C* precede *A* em 2, logo *C* vence;
- Vitória de *C*.

Para o sorteio *A* e *C*, seguido de *B*:

- Primeira rodada: *A* precede *C* em 1, *C* precede *A* em 2, logo *C* vence;
- Segunda rodada: *C* precede *B* em 1, *B* precede *C* em 2, logo *B* vence;
- Vitória de *B*.

Para o sorteio *B* e *C*, seguido de *A*:

- Primeira rodada: *C* precede *B* em 1, *B* precede *C* em 2, logo *B* vence;
- Segunda rodada: *A* precede *B* em 2, *B* precede *A* em 1, logo *A* vence;
- Vitória de *A*.

Como pode ser constatado, diante da ordem em que são sorteados os pares de *A*, *B* e *C* se alternam também os ganhadores. De fato, o último a ser confrontado possui vantagem com relações aos anteriores, em função do número de confrontos dos quais participa.

2.1.3.2 – Sistemas preferenciais

Também conhecidos como métodos de votação ordenados, trata-se de sistemas em que cada eleitor deve fornecer ordenações totais (sem empates) para todos os candidatos, podendo a saída ser um único ganhador ou uma ordenação resultante. Os principais grupos estudados em Teoria da Escolha Social são os baseados no princípio de Condorcet e os baseados na regra de Borda. Ambos serão analisados nos tópicos seguintes.

2.1.3.2.1 – Método de Condorcet e derivados

São ditos de métodos que se baseiam no princípio de Condorcet para escolha do(s) candidato(s) vencedor(es), tal qual descrito em 2.1.3.2.1. Trata-se de uma regra intuitiva e coerente com a noção de democracia, mas possui uma grande fragilidade no que se refere à universalidade, dado que em determinados cenários, ela é incapaz de eleger qualquer candidato.

Tomemos as seguintes relações de precedência entre opções *A*, *B* e *C* para todos os eleitores:

- *A* precede *B*;
- *B* precede *C*;
- *C* precede *A*.

Perceba que é impossível definir um ganhador seguindo este princípio, pois cada alternativa precede e é precedida por exatamente um candidato. Métodos baseados no princípio de Condorcet falham em emitir qualquer resultado em função deste padrão de entrada, conhecido como Paradoxo de Condorcet. Sua probabilidade de ocorrer cresce com o número de opções e de eleitores.

Várias extensões para este método foram sugeridas, sendo as principais: Método de Copeland, Método de Kemeny-Young, Método de Simpson-Kramer, Método de Sanson, Método de Baldwin, Método de Tideman, Método de Schulze, Método D'Hondt (KANGAS *et al.*, 2006).

2.1.3.2.2 – Método de Borda e derivados

Definindo, o candidato A é preferido a B se a soma da ordem em que A aparece nas listas de preferências dos eleitores é estritamente menor do que a soma correspondente de B . Assume-se com isto um valor numérico associado à posição que o candidato ocupa na lista de preferências, sendo um ao primeiro candidato, dois ao segundo, e assim por diante. Veja o exemplo a seguir:

Tabela 3 – Preferências de eleitores no exemplo do Método de Borda

Eleitores\Preferências	Opção 1	Opção 2	Opção 3
Eleitor 1	A	B	C
Eleitor 2	B	C	A
Eleitor 3	A	B	C

Para a tabela acima: A recebe $1 + 3 + 1 = 5$, B recebe $2 + 1 + 2 = 5$, C recebe $3 + 2 + 3 = 8$ e, assim, a ordenação final é $(A, B)C$. A e B estão empatados na primeira posição.

Este método possui grandes vantagens, pois verifica diversas propriedades de interesse como, por exemplo, neutralidade, anonimato, separabilidade, monotonicidade e encoraja a participação (BOUYSSOU *et al.*, 2010). Além disso, apesar de não verificar o princípio de Condorcet, ele nunca escolhe um perdedor segundo o princípio de Condorcet, ou seja, aquele que é derrotado par a par pelos demais candidatos por uma maioria absoluta de eleitores (BOUYSSOU *et al.*, 2010).

No entanto, não apresenta independência das alternativas irrelevantes. Considere para a mesma tabela acima, que C , na iminência de ser derrotado, opta por desistir da eleição. Desta forma as novas pontuações são $A = 1 + 2 + 1$ e $B = 2 + 1 + 2$, e a ordenação final é AB .

Extensões conhecidas para o Método de Borda são o Sistema de Bucklin, o Método de Coombs, Voto alternativo, Voto contingente, Método de Oklahoma (GREEN-ARMYTAGE, 2013).

2.1.4 – Medidas

O resultado esperado da aplicação das estratégias de um ponto de vista da saída observada é a geração de listas agregadas que possuam a menor distância possível para cada uma das preferências individuais. A seguir serão apresentadas algumas das medidas mais

utilizadas na área para avaliar a qualidade dos resultados, muitas das quais se originaram no campo da Estatística.

É fundamental observar que para calcular e comparar o coeficiente da lista resultante l_r , gerada por diferentes estratégias, é preciso considerar a soma do cálculo das medidas a seguir par a par entre cada lista de preferências e a lista resultante.

2.1.4.1 – Spearman's Footrule

A medida é dada pela soma das diferenças absolutas entre as posições ocupadas pelas alternativas nas duas listas. Seu cálculo pode ser descrito pela Equação 1:

$$D(l_1, l_2) = \sum_{i=1}^A |l_1(i) - l_2(i)|$$

Equação 1 – Spearman's Footrule

Como exemplo, seja l_1 dada pela sequência $\{1\ 3\ 4\ 2\}$ e $l_2 = \{1\ 4\ 2\ 3\}$. $D(l_1, l_2) = |1 - 1| + |4 - 3| + |2 - 4| + |3 - 2| = 4$.

2.1.4.2 – Coeficiente de correlação de Spearman (ρ)

Semelhante ao caso anterior, toma-se agora a soma dos quadrados das diferenças das posições ocupadas por cada alternativa em cada lista.

$$\rho(l_1, l_2) = \sum_{i=1}^A \{l_1(i) - l_2(i)\}^2$$

Equação 2 – Coeficiente de correlação de Spearman

Para o mesmo exemplo anterior: $\rho(l_1, l_2) = \{1 - 1\}^2 + \{4 - 3\}^2 + \{2 - 4\}^2 + \{3 - 2\}^2 = 6$. Seu fator quadrático penaliza mais enfaticamente passos maiores que um.

2.1.4.2 – Distância de Hamming

A distância de Hamming considera o número de posições nas quais as duas listas diferem entre si.

$$H(l_1, l_2) = \#\{i \in A: l_1(i) \neq l_2(i)\}$$

Equação 3 – Distância de Hamming

Em nosso exemplo, $H(l_1, l_2) = 0 + 1 + 1 + 1 = 3$.

2.1.4.4 – Coeficiente de correlação Tau de Kendall (τ)

Desenvolvida por Kendall em seu trabalho (KENDALL, 1938), com a motivação inicial de se encontrar uma boa medida para correlação entre duas variáveis, se tornou uma medida vastamente utilizada em diversas áreas do conhecimento. No campo de Recuperação da Informação (IR), τ de Kendall é a estatística mais utilizada para quantificar correlação entre duas listas ordenadas (YILMAZ *et al.*, 2008).

A medida de distância associada, conhecida como distância de Kendall, pode ser entendida informalmente como a distância *Bubble Sort* entre duas listas. Em outras palavras, a quantidade de permutações necessárias para que a lista *A* se torne a lista *B*.

Por se tratar de uma medida que varia bastante em função do número de opções disponíveis, o coeficiente Tau de Kendall (τ), que transmite a mesma informação no intervalo $[-1, 1]$, é preferido para efeitos de comparação em experimentos sucessivos. Sua fórmula é definida para duas listas l_1 e l_2 , e um conjunto de opções I de tamanho M , conforme mostrado na Equação 4:

$$\tau(l_1, l_2) = \frac{\#_c - \#_d}{\frac{A}{2}(A - 1)}$$

Equação 4 – Coeficiente de correlação Tau de Kendall

Onde:

- $\#_c = |(i, j) \in I: l_1(i) < l_1(j) \text{ e } l_2(i) < l_2(j)|$
- $\#_d = |(i, j) \in I: l_1(i) < l_1(j) \text{ mas } l_2(i) > l_2(j)|$

Para o exemplo: $\#_c = \{(1,2), (1,3), (1,4), (2,4)\} = 4$, $\#_d = \{(2,3), (3,4)\} = 2$,
 $\tau(l_1, l_2) = (4 - 2)/6 = 1/3$.

2.2 – Sistemas de Recomendação

Sistemas de Recomendação podem ser definidos como ferramentas de software que realizam recomendações de itens para usuários (RICCI *et al.*, 2011). Outra definição, complementar a esta, seria sistemas cujo objetivo é guiar os usuários de maneira personalizada em um grande espaço de opções (DE GEMMIS *et al.*, 2009). O intuito deste tipo de sistema é identificar o valor percebido pelos usuários, em relação aos itens de determinado domínio, e oferecer-lhes sugestões que vão ao encontro de seus interesses.

O estudo de Sistemas de Recomendação foi inicialmente motivado pela tendência com que a informação disponível na internet estava crescendo no final da década de 80 nos EUA. O correio eletrônico foi o primeiro a receber atenção, uma vez que os usuários começaram a sentir dificuldade para encontrar mensagens de e-mail relevantes em meio a uma vasta quantidade de informação de menor interesse.

Estudos desenvolvidos no MIT, neste mesmo período, já apontavam o interesse por sistemas que fossem capazes de direcionar informação de maneira personalizada. No trabalho de (MALONE *et al.*, 1987), várias sugestões de uso de sistemas inteligentes para direcionamento de mensagens eletrônicas são organizadas em um primeiro esboço do que viria a se chamar de Recomendação.

Com uma quantidade cada vez maior de informações disponibilizadas na rede e a consolidação do e-commerce na década de 90, a pesquisa se desenvolveu de tal forma que, não só a academia, mas também a indústria passaram a demonstrar interesse e começaram a investir em tais sistemas. Em (SCHAFER *et al.*, 1999), relaciona-se o aumento da importância dada a Sistemas de Recomendação devido a sua atestada capacidade de incrementar vendas cruzadas, aumentar a confiança, satisfação e lealdade de clientes a sistemas de e-commerce.

Distinguiremos dois arcabouços distintos para o problema da Recomendação. O primeiro, Sistemas de Recomendação Individual, para os quais já se estabeleceu uma densa literatura, estão fortemente baseados em conceitos advindos de áreas como Aprendizado de Máquina e Mineração de Dados. O segundo, Sistemas de Recomendação para Grupos, ao qual a proposta deste estudo se dirige, encarregam-se do problema de atender coletivamente, da melhor maneira possível, as demandas individuais de usuários organizados em um mesmo grupo.

2.2.1 – Sistemas de Recomendação Individual

São sistemas cujo principal objetivo é realizar recomendações que satisfaçam, individualmente, cada usuário. Este tipo de sistema lida com diferentes desafios, tais como, identificar o que é de interesse para o usuário; o que não deve ser recomendado; oferecer recomendações com boa variabilidade e, se possível, surpreendentes ao usuário; aprender a lidar com escassez de informação, etc..

Já existem diversos algoritmos propostos dentro do domínio de Sistemas de Recomendação Individuais, sendo uma área de estudo onde se empregou bastante esforço nos últimos anos. A categorização elaborada por (BURKE, 2002) será utilizada para guiar o leitor neste trabalho. Ele subdivide Sistemas de Recomendação Individual em cinco técnicas distintas:

- Sistemas baseados em Utilidade
- Sistemas baseados em Dados Demográficos
- Sistemas baseados em Conteúdo
- Sistemas de Filtro Colaborativo
- Sistemas baseados em Conhecimento

Ele também define algumas técnicas híbridas como, por exemplo, as que utilizam uma combinação das técnicas anteriores para realizar a recomendação. Discutiremos de maneira rápida cada uma das técnicas enumeradas por Burke. Todavia, o foco principal deste trabalho será o Filtro Colaborativo, pois é a técnica utilizada ao longo dos experimentos de Recomendação em Grupo.

2.2.1.1 - Baseados em Utilidade

Sistemas de Recomendação Baseados em Utilidade procuram mapear um modelo que faz uso de uma função de utilidade estimada para cada usuário.

A informação que constrói esta função de utilidade é obtida geralmente através de questionários respondidos pelo próprio usuário. As aproximações de maior sucesso para este tipo de sistema utilizam modelos probabilísticos, em especial, Redes Bayesianas. O exemplo a seguir é descrito em detalhes em (YI & DENG, 2009):

Dados M_1, M_2, \dots, M_n , um conjunto de atributos que descrevem um item, sendo o domínio de cada M_i , $D(M_i)$, uma faixa finita e conhecida de valores e dada a função de utilidade $u(M_i = a_i)$ e $u(M_i = a_i | M_j = a_j)$, para o usuário corrente, com $a \in D(M_i)$. Podemos construir a distribuição de probabilidade de preferências da seguinte forma:

$$P(M_i = a_i) = P(a_i) = \frac{u(a_i)}{\sum u(a_i)}$$

Equação 5 – Probabilidade de M_i assumir a_i .

$$P(M_i = a_i | M_j = a_j) = \frac{u(M_i = a_i | M_j = a_j)}{\sum_{a \in D(M_i)} u(M_i = a | M_j = a_j)}$$

Equação 6 – Probabilidade de M_i assumir a_i condicionado a M_j assumir a_j .

Onde:

- $P(M_i = a_i)$ ou $P(a_i)$ é a probabilidade de que o usuário receba a recomendação de um item descrito pela relação $M_i = a_i$.
- $P(M_i = a_i | M_j = a_j)$ representa a probabilidade do usuário receber a recomendação de um item descrito por $M_i = a_i$, dada sua preferência dominante de $M_j = a_j$.

Em seguida, uma rede Bayesiana é construída de forma a refletir as interdependências entre atributos. Dado o conjunto de todos os itens I , o conjunto de recomendações será construído como:

$$R = \{ \langle i \in I, P(M_1, M_2, \dots, M_n) > | P(M_1, M_2, \dots, M_n) > \varepsilon \}$$

Equação 7 – Conjunto de recomendação para sistemas baseados em utilidade

Sendo assim, itens que atinjam um limiar pré-estabelecido ε serão recomendados.

2.2.1.2 - Baseados em Dados Demográficos

Alguns dados demográficos como idade, gênero, classe social e local de residência podem ser diretamente obtidos durante o cadastramento de novos usuários em um sistema (ANDERSON & HIRALALL, 2011). Estes dados podem ser utilizados para identificar que determinado tipo de usuário gosta de certos itens, criando-se estereótipos.

Recomendadores, isto é, Sistemas de Recomendação, Baseados em Dados Demográficos traçam perfis de classes demográficas por meio de modelos preditivos como, por exemplo, Árvores de Decisão. Ao enquadrar um usuário em uma classe, o recomendador sugere itens relacionados ao perfil dos usuários desta mesma classe, sejam estes estabelecidos pelo especialista de negócio ou obtidos pelo retorno dos usuários.

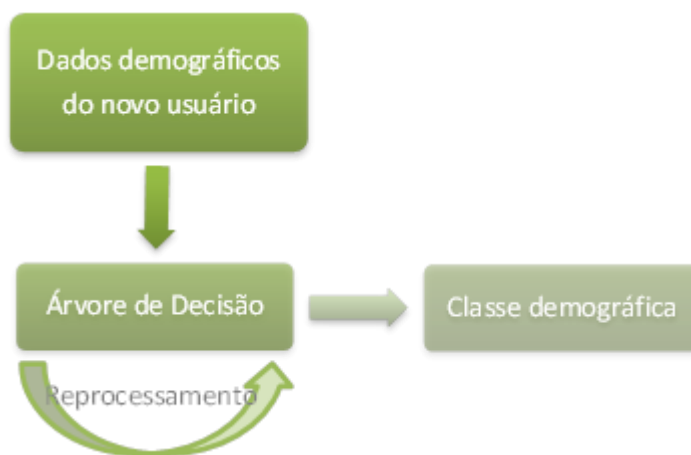


Figura 1 – Processo de recomendação em Sistemas de Recomendação Individual Baseados em Dados Demográficos

Dado que as recomendações se realizam em cima de classes demográficas, o usuário novo pode então ser imediatamente associado a uma classe e receber recomendações, sem a necessidade de que este avalie de antemão quaisquer itens na base (BURKE, 2002). Além disso, não é necessário fazer uso de qualquer informação a respeito dos atributos dos itens.

2.2.1.3 - Baseados em Conteúdo

Neste tipo de sistema, o usuário recebe recomendação de itens similares aos preferidos no passado. Estes sistemas se utilizam de informações textuais contidas nos itens, como palavras-chaves, referências cruzadas, atributos, ou ainda informações obtidas pelo uso de técnicas da área de Recuperação da Informação (BALABANOVIĆ & SHOHAM, 1997).

O processo de aprendizado em Sistemas Baseados em Conteúdo se dá pela construção de um modelo ou perfil para cada usuário, analisando os itens previamente avaliados pelo mesmo e identificando certas propriedades nos itens que agradam o usuário. Paralelamente, conforme novos itens entram na base, é realizado um processo de mapeamento de seus atributos, o que pode incluir mineração das informações descritivas e, quando possível,

também em seu conteúdo. Em seguida, estas informações são trazidas para o espaço de representação dos interesses do usuário e itens com maior similaridade são recomendados.

Uma arquitetura de alto nível é descrita em (RICCI *et al.*, 2011), onde são identificados os principais componentes que compõem as etapas realizadas por um Sistema de Recomendação Baseado em Conteúdo, a saber:

- Analisador de Conteúdo – Responsável por extrair informação estruturada e relevante a respeito dos itens, convertendo a informação contida nestes para uma forma de melhor manipulação nos passos seguintes do processo. Com frequência, os algoritmos convertem o item para um Espaço de Vetores de Termos, construídos a partir do método TF-IDF (BERRY & BROWNE, 1999).
- Máquina de Aprendizado de Perfis – Busca obter uma representação significativa e geral relativa às preferências de um usuário, construindo assim seu perfil. Para isto, são utilizadas técnicas de Aprendizado de Máquina. Em (MOONEY & ROY, 2000), temos como exemplo o uso de um Classificador Bayesiano de Texto Simples sobre os itens avaliados, positivamente e negativamente, pelo usuário. Outras implementações como Fab (BALABANOVIĆ & SHOHAM, 1997) utilizam Feedback de Relevância.
- Componente de Filtragem – Analisa o perfil do usuário e sugere itens relevantes de acordo com a representação de suas preferências. Utiliza métricas de similaridade para computar o valor de relevância do item para o usuário, sendo mais popular o uso da similaridade por cosseno.



Figura 2 – Processo de recomendação em Sistemas de Recomendação Individual Baseados em Conteúdo

2.2.1.4 - Filtro Colaborativo

Esta categoria de sistemas surgiu no meio acadêmico em 1992, sendo o termo cunhado pelo centro de pesquisa Xerox PARC e atribuído a seu sistema de filtro e direcionamento de e-mails, batizado por *Tapestry* (GOLDBERG *et al.*, 1992). A ideia principal do projeto foi a de utilizar o parecer positivo/negativo de usuários de e-mail como filtro para os demais usuários, no intuito de que somente conteúdo relevante lhes fosse apresentado.

Este método de recomendação tem como característica principal utilizar preferências explícitas dos usuários para realizar previsões de preferências para itens desconhecidos e, assim, recomendar itens em função destas previsões. Existem duas principais técnicas para tratar este tipo de recomendação: as ditas baseadas em memória e as baseadas em modelos (SU & KHOSHGOFTAAR, 2009).

Métodos baseados em memória, ou também conhecidos como “baseados em vizinhança” ou “baseados em heurística”, utilizam heurísticas sobre o espaço de avaliações, associadas a determinado conceito de proximidade entre usuários (usuário-usuário) ou entre itens (item-item), para estimar os valores desconhecidos desta matriz. Por outro lado, métodos baseados em modelo, utilizam uma série de modelos matemáticos como, por exemplo, regressão linear e classificadores probabilísticos, com intuito de preencher a matriz de avaliações.

Em geral, sistemas que fazem uso do Filtro Colaborativo valem-se exclusivamente da matriz de avaliações. Esta relaciona em suas duas dimensões usuários e itens através da avaliação do item na coluna j pelo usuário na linha i . O trabalho de (HERLOCKER *et al.*, 1999) elabora a seguinte definição fortemente baseado por esta característica: “Filtro colaborativo pode ser tratado como o problema de prever valores desconhecidos em uma matriz usuário-item”.

Uma vez realizada a previsão, o sistema sugere itens recomendados conforme alguma heurística que opere na matriz completa, sendo o algoritmo TOP-N o mais amplamente adotado. Ou seja, os N itens com a melhor avaliação prevista para o usuário são sugeridos.

2.2.1.4.1 - Baseados em Memória/Vizinhança

Esta categoria de sistemas possui como característica a definição de um critério de afinidade ou distância entre elementos para estimar a avaliação desconhecida. A heurística definida pode considerar tanto a aproximação entre itens quanto entre usuários no cálculo de uma previsão. Esta distinção será tratada a seguir pelos nomes “usuário-usuário”, quando a distância entre usuários é considerada e “item-item”, quando a distância considerada é a entre itens.

2.2.1.4.1.1 – Usuário-usuário

Nesta abordagem, a distância entre dois usuários é avaliada por meio de uma medida de similaridade utilizada no cálculo da previsão de avaliações desconhecidas. Dado um usuário, esta medida é usada como fator de ponderação com relação a todos os outros. Sendo assim, as avaliações fornecidas por usuários mais similares possuem maior peso.

Para que seja realizada a recomendação, é necessário calcular a previsão para todas as avaliações faltantes da matriz usuário-item, sendo em seguida recomendados os itens com maior avaliação estimada. A previsão pode ser definida como, dados os conjuntos de usuários U , itens I e avaliações R , é preciso construir uma função $f(u, i): U \times I \rightarrow R$, capaz de prever a avaliação de qualquer usuário u para qualquer item i .

Fixado um usuário u e os subconjuntos complementares $I'_u \cup I_u = I$, tais que I_u seja composto somente por itens já avaliados por u e I'_u por itens cuja avaliação será estimada para u . Definindo também que $I_u^* \subseteq I'_u$ é o conjunto de itens a serem recomendados para u . A tarefa de recomendação se reduz ao problema de escolher K itens para compor I_u^* segundo o critério da Equação 8 (RICCI *et al.*, 2011):

$$f(u, i') = \operatorname{argmax}_{j \in I'_u / I_u^*} f(u, j)$$

Equação 8 – Itens recomendados pelo Sistema de Recomendação Baseado em Memória com similaridade usuário-usuário

A função f pode ser vista como, dado qualquer item i ainda não avaliado, sua avaliação prevista será calculada como a soma ponderada das avaliações de usuários semelhantes, pesadas pela similaridade entre estes e o usuário em questão:

$$f(u, i) = \hat{r}_{ui} = \frac{1}{\eta} \sum_{k \in U} r_{ki} * sim(u, k)$$

Equação 9 – Função de predição das avaliações em Sistema de Recomendação Baseado em Memória com similaridade usuário-usuário

Onde:

- \hat{r}_{ui} é a avaliação estimada de u para i ;
- $sim(u, k)$ é a função de similaridade definida no problema;
- $\eta = \|\sum_{k \in U} sim(u, k)\|$ é o fator normalizador dos pesos.

Como pré-requisito ao cálculo de f , três fatores devem ser levados em consideração:

a) Normalização das avaliações

A percepção de cada usuário difere quanto ao significado da faixa de valores possíveis para as avaliações. Como exemplo, um usuário pode ser excessivamente criterioso antes de emitir uma avaliação máxima, enquanto outro pode ser otimista, emitindo esta avaliação com grande frequência.

De forma a enquadrar avaliações em um mesmo espaço de valores, a fim de poder compará-las sem este viés de opinião, o vetor que representa as avaliações de certo usuário u deve ser normalizado utilizando algum critério de normalização. Os mais usados são: Normalização Centrada na Média e Normalização Z-score (RICCI *et al.*, 2011).

b) Escolha da função de similaridade

Para a explicação a seguir, considere a notação R_a , que representa o corte do conjunto de avaliações contendo somente as avaliações do usuário a . Considere também que, uma vez normalizadas as avaliações, a função de similaridade compara dois usuários, representados aqui por u e v , fazendo uso de seus vetores de avaliações $r_u \in R_u$ e $r_v \in R_v$ no espaço $R_u \cap R_v$. Compreendendo, dessa forma, somente avaliações de itens comuns a ambos.

Algumas das métricas mais utilizadas para calcular a similaridade entre dois usuários são (RICCI *et al.*, 2011):

- Correlação por Cosseno – Considera o cosseno do ângulo formado pelos vetores r_u e r_v como uma boa representação da distância entre os usuários:

$$\cos(r_u, r_v) = \frac{r_u^T \cdot r_v}{\|r_u\| \|r_v\|}$$

Equação 10 – Correlação por cosseno

- Correlação de Pearson – Com seu primeiro registro de uso no sistema *PolyLens* (Resnick et al. 1994), o coeficiente de correlação de Pearson identifica a associação linear entre os dois vetores e é preferido como medida de similaridade em relação ao Cosseno pois desconsidera efeitos causados pela média e variância individual de cada usuário.

$$\text{cor}(r_u, r_v) = \frac{\text{cov}(r_u, r_v)}{\sigma_{r_u} \sigma_{r_v}}$$

Equação 11 – Correlação de Pearson

Onde:

- $\text{cov}(r_u, r_v) = \sum_{v_i \in I} (r_{ui} - \bar{r}_u)(r_{vi} - \bar{r}_v)$ representa a covariância entre os dois vetores para todos os itens i avaliados na interseção;
- σ_{r_u} e σ_{r_v} são respectivamente os desvios padrão dos vetores r_u e r_v .

c) Seleção de vizinhos

Em sistemas que tratam de um grande número de usuários, muitas vezes é ineficiente ou até mesmo computacionalmente inviável realizar a previsão sem antes decidir por algum tipo de filtragem sobre quais usuários considerar durante o cálculo. Os dois tipos de filtros mais utilizados para esta tarefa são (RICCI *et al.*, 2011):

- Filtro Top-N – Consideram-se somente os N usuários mais similares ao usuário em questão.
- Filtro por Limiar – Estabelece-se um limiar mínimo para a similaridade de um usuário de forma que este possa ser considerado para o cálculo da previsão.

2.2.1.4.1.2 – Item-item

Sistemas de Filtro Colaborativo baseados em vizinhança item-item partem de um princípio semelhante ao anterior para identificar a similaridade entre itens. Neste tipo de sistema, o recomendador prediz a avaliação a ser dada pelo usuário u a determinado item i ,

baseado em sua avaliação de itens similares a i . Dois itens são similares se há correlação positiva entre as notas dadas a ambos por diferentes usuários do sistema.

Em outras palavras, primeiramente são identificados que itens estão correlacionados. Chamaremos o conjunto de itens mais similares a i de I' . Em seguida verifica-se, para cada item j em I' , que avaliação foi dada pelo usuário aos itens semelhantes. Por último, realiza-se a recomendação.

Desta forma, o problema continua sendo encontrar I_u^* , conjunto que maximiza $f(u, i)$ para determinado usuário u . Para isso, precisamos saber de antemão o conjunto de itens mais similares a i , que será denotado por I' . A nova fórmula fica:

$$f(u, i) = \hat{r}_{ui} = \frac{1}{\eta} \sum_{j \in I'} r_{uj} * sim(i, j)$$

Equação 12 – Função de predição das avaliações em Sistema de Recomendação Baseado em Memória com similaridade item-item

Onde:

- $sim(i, j)$ é o valor da similaridade entre itens i e j ;
- $\eta = \|\sum_{j \in I'} sim(i, j)\|$ é o fator normalizador desta soma.

A preparação dos dados para o cálculo de f neste caso utiliza os mesmos cálculos que para a versão usuário-usuário, com essencialmente as mesmas opções de normalização, similaridade e seleção de vizinhos. Existe ainda uma métrica de similaridade que mostra bons resultados neste caso particular:

- Similaridade por Cosseno Ajustado – Trata-se de uma adaptação do coeficiente de Pearson que utiliza no lugar das médias de avaliações dos itens, valores de médias centrados nos usuários, tal qual a versão usuário-usuário. Esta medida se mostra mais efetiva do que a correlação de Pearson em filtro colaborativo baseado em item (Ricci et al, 2011).

2.2.1.4.2 - Baseado em Modelo

Esta aproximação alternativa para Filtro Colaborativo utiliza modelos matemáticos para caracterizar e resolver o problema de preenchimento da matriz de avaliações. Modelos

são usados de maneira ampla para resolver problemas diversos no mundo atual, como previsão do tempo, mercado de ações, etc. Em (SU & KHOSHGOFTAAR, 2009) descrevem-se seis abordagens de Filtro Colaborativo baseado em modelo já desenvolvidas:

- Redes Bayesianas
- Classificação Bayesiana
- Redução de dimensionalidade
- Processo de Decisão Markoviano
- Análise Semântica Latente Probabilística
- Análise de fatores esparsos

Apenas três destes modelos serão detalhados aqui, Redes Bayesianas, Classificação Bayesiana e redução de dimensionalidade.

2.2.1.4.2.1 – Redes Bayesianas

Nesta formulação, utiliza-se uma Rede Bayesiana onde cada nó representa um item do domínio e seus estados representam os valores de avaliação possíveis (encontrados na base) para cada item, com o acréscimo de um valor artificial para indicar que não há avaliação.

A rede aprendida tem a característica de que para cada item haverá um conjunto de itens pai que sejam mais relevantes para a previsão de sua avaliação. A rede funciona como uma Árvore de Decisão, na qual é possível caminhar até que se atinja uma folha, onde encontraremos as probabilidades relativas ao item pesquisado.

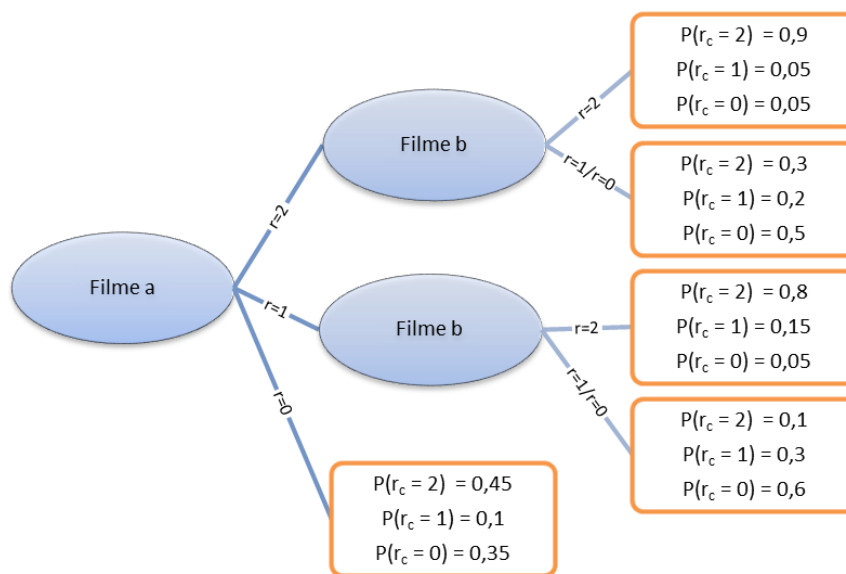


Figura 3 – Rede bayesiana ilustrativa para Filtro Colaborativo

2.2.1.4.2.2 – Classificação Bayesiana

Esta estratégia assume que usuários possam ser agrupados em segmentos de usuários similares, de tal forma que o valor de suas previsões dependa somente da categoria a qual forem atribuídos. Dado um usuário u e assumindo que este pertença a uma dada classe C , utiliza-se a formulação ingênua de Bayes para determinar a previsão de avaliação r de um usuário u para o item i . Conforme mostrado abaixo:

$$P(C = u, r_i) = P(C = u)P(r_i|C = u)$$

Equação 13 – Fórmula ingênua de Bayes para previsão da avaliação $r(i)$

Observamos que r_i torna-se independente de u dado que sua classe C é conhecida. Entretanto, encontrar $P(C = u)$ não é trivial, em função da dispersão dos dados na base. Alguns autores propõem a estimação de variáveis ocultas em modelos, a exemplo da abordagem de (BREESE *et al.*, 1998) que utiliza Maximização de Expectativas (EM) para estimar os parâmetros de uma estrutura com um número pré-fixado de classes (variáveis ocultas).

2.2.1.4.2.3 – Redução de dimensionalidade

Esta estratégia utiliza uma decomposição da matriz de avaliações original de forma a trabalhar sobre um espaço de dimensionalidade reduzida, onde se pode ser encontrar variáveis

latentes. A ideia do uso de fatores latentes advém de (DUMAIS, 2004), que utiliza tais fatores, escondidos na matriz de avaliações, para descrever aspectos observáveis, ou não, a respeito tanto dos itens quanto dos usuários considerados.

Esta família de técnicas chamou a atenção da academia após ter sido adotada por (FUNK, 2006), durante a competição realizada pelo Netflix® com o intuito de aprimorar o seu algoritmo de recomendação. Funk realizou a decomposição da matriz original através da técnica conhecida como Decomposição em Valores Singulares (SVD) (STRANG, 2006).

Em seu texto ele afirma: “Uma propriedade divertida de Aprendizado de Máquina é a de que raciocínios funcionam também ao reverso: se generalizações podem lhe ajudar a representar seus dados com menos números, então encontrar uma maneira de representá-los com menos números pode lhe ajudar a encontrar uma generalização mais significativa” (FUNK, 2006). Seu trabalho relacionou os fatores encontrados através da decomposição, dada pela fórmula da Equação 14, com características relativas tanto aos usuários (fatores em U) quanto aos itens (fatores em V^T).

$$A_{N \times M} = U_{N \times N} S_{N \times M} V_{M \times M}^T = \sum_{i < [S]} \sigma_i U_i \otimes V_i$$

Equação 14 – Fórmula para decomposição SVD da matriz A

Em seguida, a previsão das avaliações é estimada através do produto interno dos fatores latentes de cada usuário por cada item. Alguns parâmetros de ajuste são treinados utilizando as avaliações explícitas fazendo uso do gradiente descendente para otimizar o cálculo (PATEREK, 2007).

A necessidade de ajustes no modelo de Funk se explica em parte porque existem fatores relativos a usuários e itens que não dependem exclusivamente da interação entre ambos. De forma a minimizar o viés nas avaliações previstas, algumas extensões desta metodologia são propostas em (PATEREK, 2007) sendo de nosso interesse particular aquela conhecida por “*Improved Regularized SVD*”.

A técnica de recomendação individual *Improved Regularized SVD* foi utilizada no Capítulo 5 durante a validação da proposta para estimar as avaliações desconhecidas na adaptação do conjunto de dados *Movielens* para a realidade dos experimentos em grupo.

2.2.1.5 - Baseado em Conhecimento

Sistemas desta natureza sugerem itens baseados em inferências sobre as preferências e necessidades de um usuário. O sistema adquire do usuário conhecimento funcional sobre os itens, ou seja, que funções e recursos presentes nos itens atendem sua necessidade. Estas funções podem ser expressas por aspectos quantitativos, como o número mínimo de megapixels desejados em uma câmera digital, ou qualitativos, como a condição de que um restaurante ofereça cozinha oriental.

Em posse destas relações, chamadas de “consultas”, o sistema compõe uma árvore de conceitos capaz de relacionar itens que melhor se adequem a estas condições. Mais do que a recomendação imediata, o sistema armazena as consultas realizadas pelo usuário ao longo do tempo, de forma que as restrições desejadas em consultas anteriores influenciem os critérios do recomendador em resultados futuros, construindo-se assim um perfil do usuário.

Um recurso muito utilizado nestes sistemas é chamado “aumento de consulta”, em que consultas são comparadas com informações contextuais ou pessoais para refinamento dos resultados da recomendação. Dessa forma, ao receber uma consulta do tipo “cozinha oriental”, e o sistema identificar no perfil do usuário “cozinha tailandesa”, é possível que este compare a semântica de ambos os termos e utilize essa informação como critério de desempate entre inúmeras opções. Da mesma maneira, em casos de termos muito específicos, abreviações ou erros de escrita, o sistema pode aproximar, por ortografia ou semântica, outros termos de seu domínio.

Diferentes modelos são utilizados para mapear a árvore de conceitos. Alguns exemplos são o uso de ontologias e Raciocínio Baseado em Casos, como proposto por (RICCI *et al.*, 2006).

2.2.1.6 - Híbrido

Com o intuito de se beneficiar das vantagens apresentadas por cada uma das estratégias já abordadas, muitos sistemas utilizam combinações das estratégias de recomendação individual.

Métodos de hibridificação entre Sistemas de Recomendação Individual podem ser estudados em (BURKE, 2002), onde se identifica a viabilidade entre as possíveis

combinações de estratégias. No trabalho de Burke, são considerados quatro grupos de Sistemas de Recomendação Individual:

- Filtro Colaborativo;
- Baseado em Conteúdo,
- Baseado em Dados Demográficos;
- Baseado em Conhecimento/Utilidade.

Sistemas de Recomendação Baseados em Conhecimento e Sistemas de Recomendação Baseados em Utilidade são tratados como uma mesma categoria, dadas suas características comuns e por apresentarem essencialmente mesmo grupo de vantagens e desvantagens.

Tabela 4 – Cruzamento entre pares de Sistema de Recomendação Individual e número de publicações identificadas em (BURKE, 2002)

	FC	CON	DEM	BC/BU
FC	x	7	1	4
CON	x	x	2	0
DEM	x	x	x	0
BC/BU	x	x	x	x

Legenda:

FC Filtro Colaborativo
 COM Baseado em Conteúdo
 DEM Baseado em Dados Demográficos
 BC/BU Baseado em Conhecimento/Utilidade

A maneira como estes sistemas se mesclam também é categorizada por Burke, que apresenta as seguintes abordagens:

- Cálculo do peso – sistema híbrido em que a previsão da avaliação de um item utiliza mais de um recomendador.
- Alternada – O sistema alterna entre diferentes métodos de recomendação em função da situação.
- Misturada – Recomendações resultantes de diferentes recomendadores são apresentadas simultaneamente.
- Combinação de critérios – É utilizada como entrada a combinação de informações e critérios de diferentes algoritmos
- Cascata – Um recomendador refina a recomendação dada por outro

- Expansão – Recomendação de um serve como dado de entrada para o outro
- Meta-nível – O modelo aprendido por um recomendador serve como entrada para outro

2.2.2 – Sistemas de Recomendação para Grupos

Podemos definir Sistemas de Recomendação para Grupos (SRGs) como sistemas que visam recomendar itens relevantes para o interesse comum de um grupo, aplicados a situações onde pessoas se envolvem em uma mesma atividade (POPESCU & PU, 2010), por exemplo, assistir TV, escolher um destino de viagem ou ouvir música em conjunto.

Um grande contraste entre estes sistemas e Sistemas de Recomendação Individual está na tarefa de recomendar não a um, mas a um conjunto de usuários, com suas especificidades e opiniões, uma solução conjunta satisfatória. Desta maneira, podemos citar pelo menos dois contrapontos principais.

O primeiro deles é que para estudar a combinação de modelos individuais em um modelo de grupo, o próprio problema da recomendação individual é ignorado, assumindo-se assim a existência de uma boa metodologia para calcular a função de satisfação individual dos usuários (MASTHOFF, 2011).

O segundo ponto é que surge aqui uma nova restrição que caracteriza em grande parte o problema deste tipo de sistema. A versão para grupos deve atentar, em maior ou menor grau, para a minimização da angústia dos membros do grupo. Em outras palavras, os casos onde alguns membros desaprovam veementemente certos itens recomendados.

Além disso, dada à natureza social deste tipo de sistema, os algoritmos precisam fornecer mecanismos para uma interação mais rica entre usuários de um mesmo grupo. Em particular, em alguns casos, o sistema assume a responsabilidade de mediar o processo de tomada de decisão, no qual usuários expressam suas opiniões e elegem, diretamente ou indiretamente, o(s) item(s) sugerido(s).

Técnicas de recomendação em grupo também podem ser utilizadas em Sistemas de Recomendação Individual de forma a fornecer um conjunto inicial de avaliações, reduzindo o efeito conhecido como *Cold Start* (MASTHOFF, 2002). Em (O'CONNOR *et al.*, 2002) foi verificado que usuários valorizam recomendações em grupo a ponto de trocarem a privacidade de seus dados pelo benefício deste tipo de recomendação.

Um dos principais pontos que distinguem esta categoria de outras que também abordam grupos de usuários – a exemplo de Sistemas de Suporte a Decisão – refere-se ao

enfoque dado a cada uma das categorias. Em SRGs, todos os usuários possuem o mesmo peso e a finalidade geralmente envolve atividades de lazer, influenciadas pelo gosto pessoal dos usuários e não por sua expertise. Outras distinções frequentes, porém não necessárias, recaem sobre o processo decisório da recomendação, que muitas das vezes não passa pelo crivo final dos usuários.

Por outro lado, a Teoria da Escolha Social oferece um arcabouço conciso para tratar boa parte dos problemas encontrados em Sistemas de Recomendação para Grupos. A tarefa do recomendador segue aos mesmos princípios do que é conhecido na área por *função de bem-estar social* (MASTHOFF, 2004), como consequência, problemas e soluções propostas em Teoria da Escolha Social podem ser adaptados e aproveitados. A próxima seção se destina inteiramente em estabelecer o paralelo entre as duas linhas de pesquisa.

2.2.2.1 – Paralelo com a Teoria da Escolha Social

Um dos primeiros estudos a relacionar as duas áreas de pesquisa foi o trabalho de (MASTHOFF, 2004). Neste trabalho, Masthoff credita à Teoria da Escolha Social cinco das dez estratégias de Recomendação em Grupo estudadas por ela, além de sugerir que “a construção de uma função de bem-estar social é bem semelhante a nosso problema de modelagem de grupo”.

Considere as seguintes definições:

“Teoria da Escolha Social (...) se preocupa com o estudo de relações entre preferências individuais e escolha social” (FISHBURN, 1973)

“(...) ajudar indivíduos socialmente envolvidos a encontrar conteúdo de interesse a todos em conjunto (...) é o que referimos como o problema de recomendação em grupo” (AMER-YAHIA et al., 2009)

À luz destas duas citações, nota-se que o objetivo da Teoria da Escolha Social se assemelha bastante ao proposto na recomendação em grupo. Isto é, a sintetização da comunhão de interesses individuais de maneira não competitiva, ou, pelo menos não diretamente, em um modelo de preferências coletivo onde há primazia pela satisfação comum.

Uma das principais distinções entre as duas pesquisas está na representação das preferências individuais dos usuários. Na Teoria da Escolha Social, cada eleitor fornece como

entrada para o sistema a ordenação fraca dos candidatos que reflete sua prioridade de preferências. Assim, ele informa o conjunto de relações binárias de precedência dois a dois entre as opções candidatas (BOUYSSOU *et al.*, 2010).

Em SRGs, a entrada é fornecida pelos usuários (eleitores) de diferentes maneiras. Seja na forma de uma função de preferência individual, ligando cada usuário a cada item através de uma avaliação, ou através de um perfil individual composto por um conjunto de características de itens.

Além disso, há um grande foco na área de recomendação em grupo à questão prática da implementação dos sistemas de informação, levantando-se questões como tempo de resposta, interação humano-computador, mecanismos de interação de usuários via sistema, etc. (RICCI *et al.*, 2011).

Nos casos em que a representação utilizada em SRGs se dá por avaliações, é razoável propor uma tradução do conjunto de avaliações individuais, ordenadas por valor, em uma ordenação fraca das mesmas. Todavia, a forma como é realizada a captura das preferências na Teoria da Escolha Social limitaria a informação disponível às estratégias desenvolvidas em Recomendação em Grupos, e vice-versa, como veremos no tópico 2.2.2.4.1.

A tradução de volta seria igualmente problemática, visto que a escala fechada de valores de avaliação não comportaria todo o conjunto de ordenações de entrada. Por exemplo, suponha que determinado usuário estabeleça como suas preferências uma ordenação total para todos os itens da base. Esta situação requereria que a escala dos valores para avaliação fosse $[1, M]$, sendo M o número total de itens. Tamanha flexibilidade não seria viável em sistemas com um número crescente de itens, como sistemas de e-commerce. A tradução da ordenação de preferências para uma pontuação associada à posição de cada candidato na lista é realizada através do método de Borda, já apresentado em 2.1.3.2.2.

O uso de avaliações para representar preferências também abre espaço para novas estratégias propostas na área. O trabalho de (MASTHOFF, 2004) considera que as estratégias de recomendação se dividem entre aquelas cuja ênfase é colocada na satisfação individual de membros e as que priorizam a redução da miséria dos mesmos, sobretudo quando entra em conflito com a vontade da maioria no grupo. Além disso, neste mesmo trabalho, a autora

sugere como indispensável um critério de valor mínimo para que um item seja recomendado para o grupo (como em Miséria Mínima).

Não é difícil perceber que uma das vantagens na abordagem de avaliação por valores é a elasticidade do conjunto de candidatos, uma vez que se pode incluir itens indefinidamente, sem que isto exija dos usuários o reordenamento total das opções. Vale ressaltar que a representação das preferências proposta na Teoria da Escolha Social teria um impacto negativo com o crescimento do conjunto de itens no sistema, visto que o interesse do usuário em realizar tarefas complexas – como a ordenação completa de um número grande de itens – diminui conforme a complexidade aumenta (ZIPF, 1949).

Existem hoje diversos sistemas na literatura associados à recomendação em grupo, observando-se inclusive certa “miscigenação” com outras linhas de pesquisa. Veremos a seguir que, com certa frequência, alguns sistemas optam por uma etapa adicional de resolução de conflitos batizada Negociação em SRGs. Ainda que não consideremos esta etapa como a preocupação central de SRGs, ela será abordada neste trabalho.

De forma a guiar o leitor a um maior entendimento do funcionamento prático dos Sistemas de Recomendação para grupos, enumeraremos a seguir os exemplos mais citados na literatura, servindo também como linha de base para comparações ao longo do trabalho.

2.2.2.2 – Experimentos pioneiros na área

Para ilustrar esta categoria de sistemas, descreveremos aqui de alguns dos sistemas de maior expressão que serão mencionados ao longo do capítulo. Desta forma, será possível ver neles as mais variadas características de Sistemas de Recomendação para Grupos:

- *MusicFX* – Sistema que ajusta a seleção de músicas tocadas em uma academia de ginástica de forma a melhor corresponder à preferência das pessoas presentes no momento (MCCARTHY & ANAGNOST, 1998). Os usuários expressam explicitamente suas preferências acerca de diversos gêneros musicais, possuindo, dessa forma, capacidade de influenciar o recomendador. Este alternará entre as rádios que melhor correspondam aos gostos do grupo.
- *PolyLens* – Uma extensão do sistema *MovieLens* onde usuários livremente criam e se associam a grupos, podendo assim optar por recomendações individuais ou grupais de

filmes (O'CONNOR *et al.*, 2002). Neste sistema, as preferências dos usuários são estimadas pelo uso de Filtro Colaborativo Baseado em Usuário, aproveitando-se da estrutura já existente em *MovieLens*.

- *Collaborative Advisory Travel System (CATS)* – Sistema cujo objetivo chave é ajudar praticantes de esqui a chegarem a um acordo com relação a qual pacote de viagens melhor se encaixa nos seus interesses e nos interesses de outros membros do grupo (MCCARTHY *et al.*, 2006a). Possui recursos bastante avançados no nível de interação de membros de um grupo, onde usuários são capazes de imediatamente emitirem parecer a respeito da recomendação oferecida, estabelecendo restrições e solicitando mais recomendações semelhantes a uma já recebida.
- *Travel Decision Forum* – O sistema pergunta a cada um dos membros sobre suas preferências por certas características de lazer nas férias e recomenda locais de viagem que tenham maior afinidade (JAMESON, 2004). Neste sistema, membros de um grupo têm acesso às preferências de outros membros e é recorrente que compartilhem informações sobre as mesmas, muitas vezes alterando suas próprias prioridades em função de outros membros. Ao término, membros decidem que recomendação eles aceitarão, sendo possível que não haja acordo.

Diante da diversidade de características encontradas nestes e em sistemas subsequentes é difícil formular uma abordagem geral ou uma estrutura genérica o suficiente que os englobe por completo. Para que possamos entender e definir que tipo de sistema pretendemos considerar, precisamos distinguir o que chamamos aqui de “dimensões” de um SRG. Tais dimensões são referentes às escolhas que serão feitas no momento do planejamento de um SRG e cuja escolha limitará as possibilidades do mesmo.

2.2.2.3 – Dimensões

Sistemas de Recomendação para Grupos apresentam-se bastante heterogêneos entre si, cada qual com o objetivo de atender especificidades do seu domínio de atuação. Por exemplo, o aumento da complexidade da interação em um SRG exige ferramentas específicas para fins de comunicação entre os membros de um grupo.

De maneira geral, podemos subdividir SRGs conforme suas possíveis características, aqui batizadas como dimensões, muitas das quais extraídas de (MASTHOFF, 2011):

- *Captura das preferências individuais* – Podem ser aprendidas pelo sistema conforme os usuários o utilizam ou fornecidas explicitamente pelos usuários. No primeiro caso, o sistema pode aprender por *feedback* recebido em recomendações anteriores, No segundo, uma das maneiras utilizadas é aquela em que os usuários enumeram suas preferências por gêneros ou categorias, como em *MusicFX* (MCCARTHY & ANAGNOST, 1998). Ou então, o fazem diretamente item a item, como em *PolyLens* (O'CONNOR *et al.*, 2002).
- *Experiência da recomendação* – De acordo com a natureza do sistema, podemos ter os casos em que itens recomendados são experimentados imediatamente pelos usuários ou casos onde o sistema apresenta uma ou mais opções e em seguida os usuários optam por uma escolha final. Como exemplo de experimentação imediata, temos novamente o sistema *MusicFX*, onde estações de rádio são alternadas segundo a preferência dos usuários presentes na academia de ginástica. Em contrapartida, sistemas como o *Travel Decision Forum* (MCCARTHY *et al.*, 2006b) requerem que seus usuários emitam um parecer final sobre a recomendação.
- *Feedback dos usuários* – A distinção está no uso ou não deste recurso, que interfere diretamente na interação entre usuários e sistema. Em alguns casos, o sistema é capaz de interpretar o retorno imediato dado pelos usuários, recomendando novos itens em função de cada nova resposta, a exemplo do recurso de *Críticas* em *CATS* (MCCARTHY *et al.*, 2006a). Enquanto que, em outros casos, a recomendação se dá exclusivamente em função das preferências (única alternativa para sistemas onde usuários experimentam a recomendação de maneira imediata).
- *Critério de Agregação* – Outra distinção entre SRGs, no que tange ao grupo, está na maneira como o perfil do grupo é gerado. Isto pode ser realizado por uma mera agregação das recomendações individuais, pela agregação das preferências individuais ou através da criação de um modelo que represente o perfil de grupo. Maiores detalhes no tópico 2.2.2.4.2.

- *Dinamicidade dos grupos* – Uma distinção, proposta em (O’CONNOR *et al.*, 2002), atenta para possibilidade dos grupos serem estabelecidos momentaneamente pelo SRG, em oposição a grupos bem-definidos e duradouros. Além disso, refere-se também ao grau de privacidade de grupos. Estes podem ser visíveis e percebidos apenas por seus membros ou acessíveis publicamente por meio de busca.
- *Itens por recomendação* – Se distinguem em sistemas que recomendam um único item ou uma série (geralmente ordenada) de itens a cada recomendação.
- *Tamanho dos grupos considerados* – Muitos sistemas assumem ou restringem que o número de usuários por grupo seja pequeno, girando em torno de três a oito pessoas. Exemplos de grupos pequenos podem ser encontrados em *Travel Decision Forum*, restrito a três usuários (JAMESON, 2004), e nos experimentos de (AMER-YAHIA *et al.*, 2009, WANG *et al.*, 2012), onde os grupos possuem tamanho três ou oito. Já o sistema *MusicFX* considera o universo de usuários presentes na academia de musculação. O tamanho dos grupos influencia diretamente no sucesso e viabilidade de algumas estratégias de agregação, visto que com o aumento do número de membros, aumenta também a probabilidade de que certos critérios de corte eliminem mais itens do conjunto de recomendação. É o caso da estratégia “média sem miséria”, apresentada no tópico 2.2.2.4.2.3.
- *Reprise* – Um sistema pode ou não admitir que uma recomendação ocorra mais de uma vez para o mesmo usuário. As motivações para esta dimensão estão fortemente associadas aos itens do domínio da aplicação. No caso de um sistema de recomendação de músicas, é natural que títulos sejam repetidos em recomendações subsequentes. Já em Sistemas de Recomendação de filmes, livros ou destinos de viagem, é esperado que, uma vez recomendados, os itens não se repitam em listas de recomendação futuras para um mesmo usuário, mesmo que este mude de grupo. Esta dimensão interfere diretamente na recomendação, pois apenas itens não avaliados diretamente podem ser recomendados e, portanto, faz-se necessário prever as avaliações desconhecidas. Em (BALTRUNAS *et al.*, 2010), a solução proposta é a utilização de Filtro Colaborativo para o preenchimento da matriz de preferências.

- *Conhecimento Mútuo* – Característica que define a quantidade de informação que um usuário pode ter acesso referente a outros usuários do mesmo grupo. Os sistemas podem ser separados em três níveis de acesso à informação (CHEN, 2011):
 - *Primeiro nível*: Ciência dos demais membros – permite que usuários verifiquem quem são os demais usuários em seu grupo. Isto facilita os usuários tomarem uma decisão sobre como se comportar e, desta forma, aumenta a confiança dos mesmos no recomendador (CHEN, 2011).
 - *Segundo nível*: Ciência das preferências dos demais membros – permite que usuários se informem sobre as preferências de outros membros. Assim, pode-se tomar como base as preferências dos membros com os quais o usuário se identifica. Ainda referente a isto, podemos subdividir este tópico em três níveis: *zero*, onde o usuário só tem acesso às próprias preferências; *parcial*, onde um usuário pode solicitar sugestões de outros membros; ou *completa*, onde se pode ter acesso a todas as preferências de outros usuários.
 - *Terceiro nível*: Ciência do processo de decisão – distingue se o sistema possibilita que usuários acompanhem o processo de decisão de outros usuários. Também pode ser dividida em três níveis: *ciência zero*, não existe negociação entre usuários; *ciência parcial*, representantes do grupo ficam responsáveis por tomar a decisão final; e *ciência total*, usuários discutem e negociam diretamente.

Uma representação gráfica de todas as dimensões apresentadas até aqui é retratada na Figura 4:



Figura 4 – Dimensões da recomendação em grupo

Além da divisão em dimensões, podemos distinguir o funcionamento de um SRG em relação às etapas pelas quais cada sistema opera até que se concretize a recomendação. Cada uma destas etapas será abordada na próxima seção.

2.2.2.4 – Etapas

Podemos segmentar a estrutura geral de sistemas de recomendação para grupos em quatro etapas principais, ilustradas na sequência a seguir.



Figura 5 – Etapas da recomendação para grupos

Dentre as quatro etapas ilustradas, a etapa de negociação é opcional, não sendo compreendida aqui como ponto central da área de SRGs. Esta etapa é extensamente analisada na área de Sistemas de Suporte à Decisão e Negociação (BELLUCCI & ZELEZNIKOW, 1998).

2.2.2.4.1 – Captura de preferências dos usuários

Na literatura, com frequência assume-se que as preferências dos usuários estejam representadas em um domínio finito, por exemplo, na faixa de um a dez. Além disso, a maioria dos métodos propostos na literatura não lida com a incerteza, ou seja, assumem que as preferências de usuário fornecidas como entrada para as funções de agregação são precisas (CAMPOS *et al.*, 2008), ainda que em muitos casos estas tenham sido estimadas, e não obtidas diretamente.

Quando é o caso em que o sistema não obtém de forma direta as preferências de seus usuários, os sistemas utilizam diversas alternativas para estimá-las, muitas das quais são métodos da área de Sistemas de Recomendação Individual. Em *PolyLens*, a satisfação individual é vista como o resultado da previsão da avaliação de um item pelo método de Filtro Colaborativo empregado em *MovieLens* (O’CONNOR *et al.*, 2002).

2.2.2.4.2 – Agregação

Podemos considerar esta a etapa chave dos estudos em SRG. Nesta etapa, realiza-se a tarefa não trivial de agregar as informações colhidas individualmente dos usuários, com intuito de obter uma função de satisfação para o grupo.

Em (JAMESON & SMYTH, 2007) são enumeradas as três principais metodologias utilizadas para se estabelecer esta função de utilidade de grupo. São elas:

- Agregação das recomendações individuais em uma recomendação coletiva;
- Criação de um modelo de preferências de grupo;
- Agregação das preferências individuais segundo alguma heurística;

Cada uma destas metodologias será abordada a seguir. Especial atenção será dada à agregação de preferências individuais, uma vez que esta constitui a base para este trabalho.

2.2.2.4.2.1 – Agregação de recomendações individuais

A agregação de recomendações individuais consiste na união de listas de recomendação, computadas por métodos de recomendação individual, de forma a construir um conjunto de itens candidatos à recomendação (aplicável a sistemas que admitem que as preferências não estejam totalmente explicitadas).

Uma descrição formal do algoritmo é encontrada em (JAMESON & SMYTH, 2007), e inspirou a definição abaixo:

- Para cada membro $u \in G$:
 - Utilize um Sistema de Recomendação Individual para prever a lista de recomendação individual l_u
- O conjunto $C = \cup l_u$ é o conjunto candidato a recomendação

Algoritmo 1 – Procedimento para agregação de recomendações individuais

Em seguida o recomendador deve considerar quais elementos de C serão recomendados, mecanismo coberto na próxima etapa. Mesmo entre Sistemas de Recomendação que possuam um Sistema de Recomendação Individual subjacente, notamos que esta não é uma das estratégias preferidas, pelo simples fato de que a lista recomendada baseia-se apenas na opinião individual de cada membro, desconsiderando o grupo como um todo.

Uma solução que seria ótima para cada um dos membros é pouco apelativa aos demais. Além disso, este método ignora o conjunto de soluções que não é extremamente

atraente para nenhum dos membros do grupo, porém pode ser a solução ótima para o grupo (JAMESON & SMYTH, 2007).

2.2.2.4.2.2 – Modelo de preferências de grupo

Esta abordagem busca construir um modelo de grupo que atenda de forma satisfatória a opinião coletiva, baseando-se em alguma tática para agregar as preferências individuais de cada usuário. O algoritmo é bastante simples, podendo ser descrito em dois passos:

- Construa um Modelo de Preferências M que represente o grupo G
- Para cada candidato $i \in I$:
 - Utilize M para prever a avaliação r_{Gi} de i para G

Algoritmo 2 – Procedimento para previsão de avaliações em modelo de preferências de grupo

Um forte exemplo deste tipo de agregação está no sistema CATS, onde é aplicado Raciocínio Baseado em Casos para modelar a preferência conjunto dos usuários (MCCARTHY *et al.*, 2006a).

2.2.2.4.2.3 – Agregação de preferências individuais

Muitas das estratégias existentes para construção deste modelo foram emprestadas da Teoria da Escolha Social, campo que estuda como preferências individuais se agregam para formar uma preferência coletiva (MASTHOFF, 2002). Este algoritmo também é descrito em (JAMESON & SMYTH, 2007):

- Para cada $i \in I$
 - Para cada membro $u \in G$, obtenha a avaliação r_{ui} ;
 - Utilize uma estratégia de agregação para agregar todos os r_{ui} 's em uma avaliação conjunta r_{Gi}

Algoritmo 3 – Procedimento para previsão de avaliações com agregação de preferências individuais

O trabalho de (SENOT *et al.*, 2010) propõe uma separação entre as estratégias de agregação de preferências individuais em três grandes grupos, com princípios de funcionamento semelhantes: estratégias baseadas em consenso, em maioria e de bordo/fronteira. Além destes grupos, alguns algoritmos apresentam abordagens híbridas destas estratégias.

A partir daqui consideraremos por *preferência ordenada* a ordenação fraca decrescente das preferências individuais por valor de avaliação. Em função da limitação em R posições – dado que a avaliação não pode se distinguir em mais de R valores – necessariamente haverá empate entre dois itens nesta ordenação para usuários com mais de R avaliações (princípio das gavetas de Dirichlet). Nesta situação, a ordem em que itens empatados são selecionados pelas estratégias geralmente é aleatória.

2.2.2.4.2.3.1 – Estratégias baseadas em consenso

Também conhecidas por estratégias baseadas em consenso, essas heurísticas de agregação privilegiam os itens mais populares, conforme os exemplos abaixo:

- *Média*: Armazena as médias de avaliação do grupo item a item. Em seguida os itens são ordenados pela média em ordem decrescente.
- *Média sem miséria*: Princípio misto entre estratégia consensual e de fronteira. Primeiro, eliminam-se itens que possuam alguma avaliação inferior a certo limiar pré-estabelecido. Em seguida, aplica-se o mesmo critério da estratégia Média.
- *Multiplicativa*: Armazena em um vetor o produto das avaliações de todos os usuários do grupo para cada item. Em seguida, ordena-se o vetor em ordem decrescente.
- *Justa*: Sorteia-se aleatoriamente um usuário e considera-se apenas seus L itens melhor avaliados. Dentre estes, o item que cause menos miséria ao grupo (que tenha a maior nota mínima) é escolhido para a próxima posição da lista.

2.2.2.4.2.3.2 – Estratégias baseadas em maioria

Estratégias que necessariamente consideram todas as preferências de todos os membros dos grupos. Exemplos:

- *Votação plural*: A cada usuário atribui-se um voto ao item no topo de sua preferência ordenada e o item com maior número de votos é selecionado.
- *Votação por aprovação*: Um item recebe votos para cada avaliação estritamente superior a certo limiar previamente estabelecido. Em seguida são ordenados em ordem decrescente no número de votos.

- *Regra de Copeland*: Utiliza a soma do índice de Copeland para os usuários do grupo. Ou seja, um item bate os demais, para determinado usuário, se o número de vezes que sua avaliação é superior à de outros itens é maior que o número de vezes em que ela é inferior. Possíveis valores para o índice são -1, 0 e 1, de forma que a soma resultante pode ser negativa. A ordenação da lista final se dá de maneira decrescente.
- *Contagem de Borda*: Semelhante à descrita na seção 2.1.3.2.2, itens são pontuados conforme suas posições na preferência ordenada dos usuários, em ordem crescente a contar da posição um (ou zero). A diferença aqui é no caso de empate, em que é tomada a média das posições englobadas pelos itens empatados (ex.: posições 3, 4, 5, 6 ∴ média 4,5), e este valor é atribuído aos mesmos. Ordena-se em ordem crescente.

2.2.2.4.2.3.3 – Estratégias de fronteira

As estratégias de fronteira privilegiam um subconjunto de itens nos perfis individuais, baseadas em critérios ou papéis.

- *Miséria Mínima*: A avaliação de um item no perfil de grupo corresponde a sua menor nota dentre todos os membros do grupo. Em seguida, itens são ordenados por esta definição em ordem decrescente. Esta abordagem está fundamentada na ideia de que, em pequenos grupos, a satisfação geral se resume à satisfação do menos satisfeito de seus membros (O'CONNOR *et al.*, 2002).
- *Prazer Máximo*: Utiliza princípio semelhante ao anterior, mas considera-se apenas a maior avaliação do item dentre os membros do grupo.
- *Ditatorial*: Apenas as avaliações de um único usuário são consideradas como modelo para o grupo, geralmente por estar a ele atribuído determinado papel.

2.2.2.4.2.3.4 – Estratégias híbridas

Em muitos casos, os SRGs adotam uma estratégia de agregação híbrida ou alternam a estratégia de acordo com certa condição. O sistema *PolyLens* utiliza Filtro Colaborativo baseado em memória para prever as preferências dos usuários em relação a todos os itens. Em seguida, aplica-se a estratégia de agregação Miséria Mínima (JAMESON & SMYTH, 2007).

Já em *MusicFX*, uma versão própria de Média sem Miséria foi desenvolvida, de forma a trazer as preferências para valores positivos (a entrada deste sistema está na faixa [-2, 2]) e

umentar a distância entre estilos menos e mais populares (MCCARTHY & ANAGNOST, 1998). A fórmula utilizada foi:

$$rel(G, i) = \sum_{u \in G} (r_{ui} + 2)^2$$

Equação 15 – Média sem Miséria em *MusicFX*

Onde que r_{ui} define a preferência do usuário u pelo item i .

Alguns autores abordam a importância da função agregadora apresentar algum grau de equidade (JAMESON & SMYTH, 2007) e (AMER-YAHIA *et al.*, 2009), sugerindo para o cálculo da satisfação uma componente negativa, em função do desvio padrão das avaliações dentro de um mesmo grupo.

A equação para o cálculo da relevância de um grupo pode ser reformulada para:

$$rel(G, i) = Agr(G, i) - w \cdot Dis(G, i)$$

Equação 16 – Fórmula para relevância com fator de dissimilaridade

Onde:

- $Agr(G, i)$ se refere a algum dos métodos de agregação acima definidos;
- $Dis(G, i)$ é a função de discordância, componente função dos desvios;
- w representa um fator de peso para o ajuste da equidade.

A explicação para este cálculo extra é considerar também os gostos individuais, almejando, por exemplo, equilibrar o atendimento às preferências de cada um dos membros de forma equânime. Por exemplo, em um cenário de recomendação de programação de TV, um membro que já esteja bem atendido por maior parte das recomendações pode sacrificar assistir a uma programação com baixo apelo, em detrimento a outro membro que ainda não tenha sido contemplado suficientemente.

Algumas funções são sugeridas por (AMER-YAHIA *et al.*, 2009) para o fator de discordância $Dis(G, i)$ na Equação 16, estas são:

- *Discordância média par-a-par:*

$$Dis(G, i) = \frac{2}{|G|(|G| - 1)} \sum_{u, v \in G, u \neq v} (|r_{ui} - r_{vi}|)$$

Equação 17 – Discordância par a par

- *Variância da Discordância:*

$$Dis(G, i) = \frac{1}{|G|} \sum_{u \in G} (r_{ui} - \bar{r}_i)^2$$

Equação 18 – Variância da Discordância

Em que \bar{r}_i representa a média das avaliações recebidas pelo item i dos usuários de G .

Na prática, uma grande desvantagem da aplicação do fator de discordância par-a-par está na sua complexidade computacional. A complexidade é de ordem fatorial, mesmo com o uso de alguma heurística para pré-selecionar itens que serão computados (JAMESON & SMYTH, 2007).

2.2.2.4.3 – Recomendação

Ao término da etapa anterior, o sistema deve realizar a recomendação de itens em função dos valores de satisfação dos mesmos, encontrados para aquele grupo. Em alguns sistemas, a exemplo de sistemas onde ocorre experimentação imediata da recomendação, esta já pode ser considerada a etapa final, pois o sistema arbitrariamente impõe uma decisão. Em outros, é solicitado ao grupo um último parecer, etapa conhecida como Negociação e que será tratada no próximo tópico.

A etapa de Recomendação se distingue em diversos aspectos referentes à forma como a recomendação será apresentada, por exemplo, se a recomendação se dá de forma interativa ou não; se serão considerados de um ou muitos itens; no caso de serem muitos itens, se estes serão exibidos simultaneamente ou em sequência, ordenados ou não, etc.. Uma descrição formal para o problema tratado nesta etapa é apresentado em (AMER-YAHIA *et al.*, 2009) e será descrito a seguir.

Dado um grupo G , e a função de satisfação de grupo $rel(G, i)$, identificar a lista de itens I_G , tal que:

1. $|I_G| = k$, cujos elementos estão em ordem decrescente de satisfação

2. $\forall i \in I_G, u \in G, u$ ainda não avaliou i
3. $\nexists j \in I \mid i \in I_G, rel(G, j) > rel(G, i)$, ou seja, a satisfação de grupo dos itens em I_G é máxima dentre as demais opções em I

Ainda que aplicável a muitos casos, esta definição não é suficientemente geral, tendo em vista que nem sempre faz sentido considerar a segunda premissa. Assim, pode haver sistemas em que itens já avaliados possam ser novamente recomendados, por exemplo, estações de rádio em *MusicFX*.

Assumindo que possuímos o valor satisfação dos itens candidatos, resta definir se iremos considerar somente a satisfação de grupo, ou se fatores relativos a gostos individuais serão combinados, com o intuito de recomendar com maior equidade. No primeiro caso, a recomendação pode ser obtida imediatamente através da escolha dos primeiros K itens em ordem decrescente de satisfação de grupo.

Já quando consideramos também os gostos individuais, a exemplo das componentes de Discordância descritas no item anterior, uma função mais elaborada é necessária. Em geral, nestes casos, utiliza-se variações do Algoritmo de Limiar, a exemplo do algoritmo de Listas de Discordância Completamente Materializadas descrito em (AMER-YAHIA *et al.*, 2009).

No sistema *Collaborative Advisory Travel System* ou *CATS*, a etapa de Recomendação pode se dar de duas maneiras distintas. Através de uma interface gráfica no formato de mapa, os usuários inicialmente emitem suas preferências por características de pacotes de viagem.

A estes pareceres atribui-se o termo *Críticas*, constituindo uma forma de retorno sobre os atributos que agradam/desagradam o usuário atual. A partir das *Críticas* o sistema é capaz de, ao mesmo tempo, oferecer recomendações individuais que mais se adequem aos requisitos específicos de cada usuário, como também alimentar um modelo de grupo onde as *Críticas* aparecem como leves restrições, muitas vezes até conflitantes na composição do modelo (MCCARTHY *et al.*, 2006a).

(MCCARTHY *et al.*, 2006a) identifica neste sistema duas formas de recomendação:

- *Recomendação Reativa* – Em função das *Críticas* recebidas, o sistema é capaz de oferecer recomendações que correspondam melhor aos gostos do usuário individual, aprendendo desta forma suas preferências;

- *Recomendação Proativa* – Conforme o grupo adiciona *Críticas* à sessão, o modelo de grupo se aperfeiçoa, até que se atinja um limite no qual um item possua grande compatibilidade com boa parte das *Críticas* feitas até o momento. Desta forma, o item é recomendado como solução a todos os usuários.

2.2.2.4.4 – Negociação

Esta etapa considera a decisão final do grupo com relação às recomendações recebidas. Ou seja, o sistema abre a possibilidade para que usuários debatam a decisão sobre que recomendação será aceita pelo grupo.

Muitos recomendadores evitam a questão da negociação por meio de alguns dos seguintes meios: ditam imediatamente a recomendação baseados em alguma heurística automática (caso de *MusicFX*); denominam um membro como líder, sendo este responsável pela decisão final; ou se isentam da responsabilidade de mediar este nível de interação, assumindo que usuários se encontram frente-a-frente para debaterem (JAMESON, 2004).

No *Travel Decision Forum*, pode-se interagir por meio de uma interface gráfica, que contém dois principais mecanismos de comunicação e expressão de opinião. O primeiro trata-se de um painel de controle individual, onde tanto é possível definir/modificar preferências referentes às características desejadas do local de destino, como também é permitido ao usuário emitir sua inclinação em ceder a cada um dos outros membros do grupo.

A segunda maneira de interação via sistema se dá por meio de um agente virtual, representado por uma animação caricaturada (*avatar*) dos participantes do grupo que expressam as opiniões de seus respectivos usuários, mostrando comportamento coerente com suas preferências.

Existe ainda a figura de um mediador, que apresenta sugestões quanto às possíveis mudanças nas características individuais, a fim de obter consenso. A decisão se dá quando os membros concordam com o mediador em uma proposta que contenha as características consensuais do local de destino (JAMESON, 2004).

Em *CATS*, membros podem realizar propostas de itens que lhes chamem a atenção através de uma área comum denominada *Stack Area*. A negociação se dá através de pareceres emitidos pelos usuários referentes aos atributos contidos nos itens avaliados, chamados

Críticas. Os usuários também podem realizar *Críticas* conflitantes e, desta forma, a Crítica mais recente sobrescreverá a anteriormente feita (MCCARTHY *et al.*, 2006a). A decisão é tomada quando todos os usuários concordam com um dos destinos propostos até o momento, seja por via do recomendador ou por sugestão de um usuário.

2.2.2.5 – Medidas aplicadas em SRGs

A fim de avaliar a qualidade dos resultados, diversas medidas foram emprestadas da Teoria da Escolha Social, entre outras áreas do conhecimento. Em especial, a medida mais utilizada em SRGs provém da área de Recuperação da Informação (RI).

A medida Tau de Kendall, já apresentada no tópico 2.1.4.4, se mostra particularmente eficiente para indicar convergência/divergência entre usuários e a recomendação, mas carece de pelo menos uma propriedade desejada, que é a ponderação da relevância dos primeiros resultados. Uma vez que o processo de recomendação aplica o corte *TOP-K* à lista recomendada, a precisão na ordenação global da lista reduz em importância conforme a posição se aproxima à *K* e é irrelevante a partir disto. A garantia de que candidatos realmente fortes surjam primeiro na lista de recomendação deve ser prioritária.

Atendendo a esta demanda, algumas outras medidas são mais oportunas, mais especificamente as utilizadas na avaliação de desempenho de motores de busca. Espera-se que opções bastante relevantes estejam bem posicionadas na lista do grupo e que a medida seja sensível a isto. A medida *nDCG*, como veremos a seguir, demonstra atender esta e outras propriedades.

2.2.2.5.1 – Ganho Cumulativo Descontado Normalizado (nDCG)

A medida *nDCG* é uma medida atual em RI (JÄRVELIN & KEKÄLÄINEN, 2002) e se consolidou na avaliação de motores de busca, devido a sua capacidade de levar em consideração a relevância dos primeiros resultados apresentados, decaindo de forma logarítmica o peso do item conforme sua posição cresce na lista de recomendação.

Esta medida se trata da normalização da medida *DCG*, de forma que a soma total dos pesos se encontre no intervalo $[0, 1]$ e, assim, os resultados de diferentes cenários sejam comparáveis. Para que a pontuação obtida por uma lista seja normalizada, é preciso que se defina uma lista ideal, que possuiria pontuação seja máxima. Para os experimentos em

Recomendação em Grupos, a medida é calculada usuário a usuário, visto que se soubéssemos a lista ideal para o grupo, todo o esforço despendido na etapa de Agregação seria em vão.

A fórmula para $nDCG$ é definida para a lista resultante l_r e lista ideal l_l como:

$$nDCG(l_r, l_l) = \frac{DCG(l_r)}{DCG(l_l)}$$

Equação 19 – Fórmula de nDCG

Em que a medida DCG constitui-se por:

$$DCG(l) = r_1 + \sum_{k=2}^K \frac{r_k}{\log_2 k}$$

Equação 20 – Fórmula de DCG

Onde:

- r_i – pontuação do item na posição i
- K – linha de corte definida para a medida, seu valor padrão é 10

A pontuação r_i pode se dar de diversas formas. Para resultados de busca, $r_i = 1$ caso o item na posição i conste no conjunto de testes, caso contrário, $r_i = 0$. Outras escalas consideram também, por exemplo, a ordem em que os resultados são esperados no conjunto de testes. Geralmente avalia-se DCG para os primeiros K itens da lista recomendada, trabalhando-se com o valor truncado desta estatística.

Capítulo 3 – Proposta de estratégia: Usuário Mais Representativo

Neste capítulo, apresentaremos a proposta deste trabalho, cujos esforços estão voltados para a etapa de Agregação. As implicações da adoção da técnica proposta serão analisadas por diversos aspectos, incluindo uma análise de suas propriedades, suas vantagens e suas limitações.

3.1 – Introdução

Muitas propostas foram desenvolvidas em recomendação para grupos, na esperança de resolver, de maneira ótima, cada uma das etapas do problema. Apresentamos no capítulo anterior, item 2.2.2.4, algumas das principais iniciativas para enfrentar os problemas de Captura de Preferências, Agregação, Recomendação e Negociação.

Nossa proposta consiste em uma nova metodologia de agregação de preferências para resolver o problema de Agregação. Antes de explicar a solução proposta, definiremos formalmente o problema de Recomendação em Grupo.

3.2 – Formalização matemática do problema

O problema tratado nos estudos de Recomendação em Grupo consiste em buscar uma estratégia que possibilite obter recomendações para grupos de usuários, de maneira a otimizar a satisfação individual dos membros simultaneamente. Tendo isso em vista, assuma as seguintes definições:

$U = \{u_1, u_2, \dots, u_N\}$ – Espaço de usuários de tamanho N

$I = \{i_1, i_2, \dots, i_M\}$ – Espaço de itens de tamanho M

R – Conjunto de valores admissíveis para as avaliações, geralmente $R \subset \mathbb{N}^*$

$G \subset U$ – Grupo de usuários de tamanho $K \leq N$

$L \subset I$ – Lista sequencial de itens, truncada em $T \leq M$, e $L[x \dots z]$, a sub-lista de L iniciando na posição x e terminando na posição z

$\theta_u(I) \rightarrow R$ – Função que mapeia preferência/satisfação do usuário u para cada item em I em um escalar em R

$\theta_G(I) = f(\theta_{u_1}(I), \theta_{u_2}(I), \dots, \theta_{u_K}(I))$ – Preferência conjunta do grupo $G = \{u_1, u_2, \dots, u_K\}$.

De modo a simplificar as próximas equações, assumiremos, tanto para $\theta_u(I)$ quanto para $\theta_G(I)$, que, para uma entrada composta por um vetor ordenado de itens, a função retornará um vetor de mesmo tamanho contendo as satisfações dos respectivos itens.

O objetivo do estudo é encontrar uma lista agregada ideal L_{max} que satisfaça:

$$\{\forall i_x \in L_{max} \mid \theta_G(i_x) \geq \operatorname{argmax}\{\theta_G(I - L_{max})\} = \theta_G(i_{x+1})\}$$

Equação 21 – Regra de formação dos elementos de L_{max}

Não identificamos na literatura qualquer definição direta para $\theta_G(I)$. De fato, se tal definição existisse, não haveria razões para estudar a etapa de Agregação, visto que a solução ótima se daria pela simples ordenação dos resultados gerados por θ_G para todos os itens em I . Em agregações que utilizam modelos de grupo, o resultado final do extensivo processo de treinamento pode ser visto como uma caixa-preta cujo principal objetivo é aproximar θ_G .

Uma abordagem exaustiva para o problema seria a geração de todos os arranjos simples de I , com tamanho T , em busca da solução que atenda à restrição da Equação 21. No entanto, a natureza combinatória do problema torna a busca neste espaço computacionalmente inviável para fins práticos. Desta maneira, diversas heurísticas foram desenvolvidas para aproximar o comportamento da função de preferência conjunta do grupo, batizadas estratégias de agregação de preferências.

Tais tentativas de generalização da satisfação de grupo baseiam-se em aspectos observados na lista ideal (L_{max}) e procuram simular algumas características tais como:

- a. Um alto valor médio de satisfação individual;
- b. Uma baixa discordância entre a ordem dos elementos na lista recomendada e a ordem dos elementos nas listas de preferências ordenadas dos usuários;
- c. Uma baixa ocorrência de miséria entre membros do grupo em relação a seus itens. Situação em que usuários possuem satisfação inferior a certo patamar, considerado baixo.

Na ausência de uma definição para θ_G , o sucesso de uma agregação deve ser medido também de maneira indireta, visto que não podemos pagar o custo de descobrir a lista ideal.

Para isso, utilizam-se medidas que se baseiam exclusivamente nas preferências individuais. A medida mais largamente aceita e utilizada em trabalhos de Recomendação em Grupo é o Ganho Cumulativo Descontado Normalizado (nDCG). Como apresentado na seção 2.2.2.5.1, nDCG utiliza uma função de pontuação que decai com a posição do item na lista de recomendação, o que a torna capaz de distinguir e enfatizar desacordo no topo em relação ao final da lista de recomendação.

Além desta medida, neste trabalho utilizamos também o coeficiente Tau de Kendall, emprestada da Teoria da Escolha Social. Esta medida nos informa o grau de discordância entre as ordenações das preferências individuais e a lista gerada pela estratégia de agregação. Apesar de não ser suficiente para uma avaliação completa do resultado, observamos durante os testes que a informação verificada por esta medida não é captada pela medida nDCG, justificando sua escolha.

3.3 – Estratégia proposta

Neste trabalho propomos uma estratégia de agregação de preferências dos usuários, de forma a compor as preferências do grupo. A ideia principal é identificar, no espaço de preferências, um usuário mais representativo para o qual efetivamente recomendar. Além disso, pretendemos nos valer apenas das preferências de usuários do grupo, sem contar com qualquer informação auxiliar de contexto. Batizamos esta proposta de Usuário Mais Representativo.

Podemos encontrar algumas estratégias na área com princípios semelhantes a nossa proposta, são elas “Pessoa Mais Respeitada” (MASTHOFF, 2002) e “Ditatorial” (SENOT *et al.*, 2010). Elas são comparáveis no que tange a escolha das preferências de um único usuário, a fim de representar as preferências do grupo. No entanto, o critério utilizado aqui não se vale de qualquer informação extra, a não ser a matriz de preferências, e tampouco utiliza um sorteio aleatório para escolha do usuário ditador.

Durante a concepção da presente proposta, consideramos também a possibilidade de agregar preferências de um subgrupo mais representativo. No entanto, esta abordagem recairia no problema original, pois a dificuldade de obter um bom modelo conjunto de preferências é a mesma para qualquer subgrupo de tamanho maior que um.

O principal pressuposto de nossa estratégia é assumir a ocorrência de certos padrões nas preferências individuais, de forma que seja possível encontrar um estereótipo para o grupo, ou seja, um usuário que possa representar o grupo como um todo. É então tomado o usuário *medóide* deste espaço de preferências – aquele que possua a menor distância para os demais de acordo com uma função de distância pré-estabelecida. A função de preferências do usuário *medóide* representará a função de preferências do grupo:

$$\theta_G = \theta_w \because u_1, u_2, \dots, w, \dots, u_K \in G, D(w) = \min\{D(u_1), D(u_2), \dots, D(u_K)\}$$

Equação 22 – Função de preferência do grupo para o método Usuário Mais Representativo

Onde:

$D(u) = \sum_{v \in G} d(u, v)$ – somatório da função de distância aplicada par-a-par com os demais usuários

Na ocorrência de mais de um mínimo, a função *min* deverá sortear aleatoriamente um dos usuários com $D(u)$ mínimo. Uma possível escolha para a função de distância d é a distância Euclidiana (ver Equação 23), sua aplicação nos dá uma noção geométrica do afastamento entre usuários. Além de intuitiva, o custo de processamento necessário para calculá-la é baixo, considerando os tamanhos de grupo tratados.

$$d(x, v) = |\vec{\theta}_v - \vec{\theta}_x|$$

Equação 23 – Distância euclidiana para dois vetores de preferências

Com frequência, utilizaremos uma noção ainda mais simples de distância em nossos exemplos ilustrativos, a distância Manhattan (Equação 24). Esta definição de distância é preferida nos exemplos, pois pode ser facilmente calculada, tendo como base a matriz de preferências.

$$d(x, v) = \sum_{i \in I} |\theta_v(i) - \theta_x(i)|$$

Equação 24 – Distância Manhattan para dois vetores de preferências

A estratégia proposta não está limitada a realizar as operações diretamente na matriz de preferências. Para o raciocínio a seguir, considere como matriz de preferências R a matriz cujas linhas são compostas pelas preferências individuais dos K usuários do grupo em relação

aos M itens (colunas). Tomemos a Decomposição em Valores Singulares (STRANG, 2006) sobre esta matriz, na forma:

$$R_{K \times M} = U_{K \times K} S_{K \times M} V^T_{M \times M}$$

Equação 25 – Matrizes na Decomposição em Valores Singulares (SVD)

Em que U é ortonormal, e suas colunas são os vetores singulares à esquerda de R ; S é diagonal e possui os valores singulares de R ; e as linhas de V^T são os vetores singulares à direita de R . Em ambas as matrizes U e V^T , os vetores singulares aparecem ordenados por significância. Se tomarmos apenas os r primeiros vetores destas matrizes, seremos capazes de construir uma aproximação de posto r da matriz original.

Dada esta definição, é possível enxergar as colunas da matriz U como fatores latentes e as linhas como representação de cada usuário no espaço definido por estas colunas. Podemos aplicar o mesmo princípio anterior para encontrar o usuário *medóide* neste novo espaço, de forma a considerar suas preferências.

3.4 – Propriedades da Proposta

Utilizando as propriedades levantadas na Teoria da Escolha Social, podemos traçar alguns paralelos com as estratégias de Recomendação em Grupo, no que diz respeito à capacidade de cada qual atender certas condições de justiça. Arrow prova que nenhuma função de bem-estar social é capaz de atender simultaneamente um subconjunto de cinco destas propriedades, universalidade, unanimidade, transitividade, independência das alternativas irrelevantes e não ditatoriedade (como visto em 2.1.2).

O objetivo desta seção é realizar uma análise de estratégias de recomendação sob a ótica dessas propriedades, no intuito de sinalizar características positivas e negativas de nossa proposta. Começaremos descrevendo as cinco propriedades de Arrow e utilizaremos como referência a estratégia Usuário Mais Representativo, comparando-a, quando pertinente, com as estratégias Ditatorial, Média Simples, Média sem Miséria e/ou Miséria Mínima.

Para que seja possível qualquer comparação, as estratégias de agregação de preferências devem ser transformadas em funções de bem-estar social. É importante frisar que a mera tradução direta das avaliações dos usuários para uma ordenação fraca das preferências

individuais não seria uma operação equivalente, em função de não haver tradução direta entre as duas representações.

Ilustraremos esta incompatibilidade com dois exemplos. Primeiramente, seja $\vec{R}_u = (R_a, R_b, R_c, R_d)$ o vetor de avaliações para um usuário u , na escala $[1, 5]$, dos itens a, b, c, d . A tradução de \vec{R}_u para a ordenação fraca R_u seria expressa por:

$$\vec{R}_u = (5, 4, 1, 1) \implies R_u = ab(cd)$$

Equação 26 – Tradução de preferências de usuário expressa em vetor de avaliações para ordenação fraca

Suponha que queremos aplicar a estratégia Média Sem Miséria com valor de corte igual a dois a ambas as entradas. Notamos que é impossível realizar a tarefa sobre R_u dado que a informação sobre o valor numérico se perde durante a tradução, logo as duas representações não são equivalentes.

Da mesma forma, a tradução de volta sofrerá, por exemplo, com a questão da escala de valores de \vec{R}_u . Imagine que tenhamos também os itens e, f e g . Se utilizarmos o critério de tradução em que a maior avaliação é atribuída ao primeiro colocado, a segunda maior ao segundo, e assim por diante, teremos:

$$R_u = dcab(ef)g \implies \vec{R}_u = (3, 2, 4, 5, 1, 1, ?)$$

Equação 27 – Tradução de preferência de usuário expressa em ordenação fraca para vetor de avaliações

Dado que a escala de \vec{R}_u permite que se assumam valores somente entre um e cinco, é impossível representar R_u como \vec{R}_u sem perda de informação. Dessa forma, não faremos aqui qualquer tradução da informação de entrada. Preferimos adaptar as definições de cada estratégia de agregação para funções de bem-estar social estendidas, capazes de operar diretamente sobre \vec{R}_u . Mas que continuem retornando uma ordenação fraca como saída.

O intuito de manter a mesma saída é o de permitir o uso de conclusões de ambas às áreas a respeito dos resultados obtidos.

3.4.1 – Conversão de estratégias de agregação para funções de bem-estar social

“Por função de bem-estar social, entende-se o processo ou regra pela qual um conjunto de ordenações individuais R_1, R_2, \dots, R_N é levado a uma correspondente ordenação social R ” (ARROW, 1951)

Em nossa adaptação utilizaremos vetores de preferência como entrada, mas manteremos a saída como uma ordenação fraca. De forma complementar, por vezes a notação matricial $\mathcal{R}_{N \times M}$ para o conjunto de entrada, poderá ser referida, em que $r_{u,i}$ representa a avaliação do usuário $u \in U$ em relação ao item $i \in I$. Além disso, utilizaremos o símbolo \wedge para o E lógico, \neg para o NÃO, \vee para OU e \rightarrow para IMPLICA.

Uma relação binária R qualquer em um conjunto I é um subconjunto de $I \times I$; frequentemente referida como aRb , ao invés de $(a, b) \in R$. Uma ordenação fraca em I é uma relação binária em I , completa ($\forall a, b \in I$ temos aRb e/ou bRa) e transitiva ($\forall a, b, c \in I$, temos que aRb e bRc implica aRc). Seja também $\mathcal{OF}(I)$ o conjunto de todas as ordenações fracas de I . A parte assimétrica de R é a relação binária P definida por $aPb \Leftrightarrow [aRb \wedge \neg bRa]$. A parte simétrica é a relação Q definida por $aQb \Leftrightarrow [aRb \wedge bRa]$ (BOUYSSOU *et al.*, 2010).

Em poder destas definições, seguiremos com a modelagem das funções de bem-estar social.

3.4.1.1 – Média Simples

Para cada $a, b \in I$, a função de bem-estar social Média Simples é definida por $R = F(\vec{R}_1, \vec{R}_2, \dots, \vec{R}_N)$, tal que:

$$\begin{cases} aPb \Leftrightarrow \sum_{\forall u} r_{u,a} > \sum_{\forall u} r_{u,b} & (A1) \\ aQb \text{ caso contrário} & (A2) \end{cases}$$

3.4.1.2 – Ditatorial

Para cada $a, b \in I$, a função de bem-estar social Ditatorial é definida por $R = F(\vec{R}_1, \vec{R}_2, \dots, \vec{R}_N)$, tal que:

$$\text{Sorteie } \vec{R}_d \text{ aleatoriamente de } \{\vec{R}_1, \vec{R}_2, \dots, \vec{R}_N\}$$

$$aPb \Leftrightarrow r_{d,a} > r_{d,b} \quad (A1)$$

Em caso de empate, em que $r_{d,a} = r_{d,b}$, não é obrigatório que aQb , sendo admissíveis tanto aPb ou bPa . Veremos a seguir que a versão formal do critério de não-ditatoriedade não estabelece regras para o desempate.

3.4.1.3 – Usuário Mais Representativo

Para cada $a, b \in I$, a função de bem-estar social Usuário Mais Representativo (MRU – *Most Representative User*) é definida em duas etapas. Primeiramente, encontra-se $\vec{R}_{MRU} \in \{\vec{R}_1, \vec{R}_2, \dots, \vec{R}_N\}$ através da aplicação de uma função que chamaremos *medóide*. Esta função é responsável por retornar o vetor que minimize determinada medida de distância dois a dois para os demais vetores. Portanto:

$$\vec{R}_{MRU} = \begin{cases} N < 3, \text{ sorteio aleatório} \\ N \geq 3, \text{ medóide}(\vec{R}_1, \vec{R}_2, \dots, \vec{R}_N) \end{cases}$$

Em seguida, $R = F(\vec{R}_1, \vec{R}_2, \dots, \vec{R}_N)$, é obtida por:

$$\begin{cases} aPb \Leftrightarrow r_{MRU,a} > r_{MRU,b} \quad (A1) \\ aQb \Leftrightarrow r_{MRU,a} = r_{MRU,b} \quad (A2) \end{cases}$$

Nos exemplos, a medida de distância utilizada será a soma dos módulos das diferenças item-a-item com os demais vetores de avaliação.

3.4.1.4 – Média sem Miséria

Para cada $a, b \in I$, a função de bem-estar social Média sem Miséria é definida por $R = F(\vec{R}_1, \vec{R}_2, \dots, \vec{R}_N)$, tal que para determinado valor de avaliação l :

$$\begin{cases} \exists u [r_{u,a} < l \vee r_{u,b} < l] \Leftrightarrow (a, b) \notin R \wedge (b, a) \notin R & (A1) \\ aPb \Leftrightarrow \sum_{\forall u} r_{u,a} > \sum_{\forall u} r_{u,b} & (A2) \\ aQb \text{ caso contrário} & (A3) \end{cases}$$

3.4.1.5 – Miséria Mínima

Para cada $a, b \in I$, a função de bem-estar social Miséria Mínima é definida por $R = F(\vec{R}_1, \vec{R}_2, \dots, \vec{R}_N)$, tal que:

$$\begin{cases} aPb \Leftrightarrow \min(\mathcal{R}_{*,a}) > \min(\mathcal{R}_{*,b}) & (A1) \\ aQb \text{ caso contrário} & (A2) \end{cases}$$

Onde $\min(\vec{r})$ é a função que retorna o menor elemento do vetor \vec{r} e a notação “*” aplicada a uma das dimensões da matriz \mathcal{R} refere-se à seleção de todos os elementos desta dimensão.

3.4.2 – Definição formal das propriedades e aderência das estratégias

Em posse das definições acima, somos agora capazes de estabelecer um paralelo mais consistente entre as duas áreas. A seguir, testaremos a aderência das estratégias citadas a cada uma das propriedades do Teorema de Arrow e pontuaremos a interferência de algumas das dimensões da Recomendação em Grupo na garantia ou anulação das mesmas.

3.4.2.1 – Universalidade

Uma função de agregação F deve retornar uma ordenação fraca coletiva para qualquer conjunto $\{\vec{R}_1, \vec{R}_2, \dots, \vec{R}_N\}$.

A universalidade ou domínio irrestrito é uma propriedade que tem por fim garantir que nenhuma suposição ou restrição seja estabelecida sobre o conjunto de entrada. Cada usuário pode avaliar todos os itens com quaisquer valores na faixa utilizada pelo sistema de recomendação. Uma função de bem-estar social é não universal quando, por exemplo, exige que os vetores de preferências apresentem ordenação total (sem empates).

As estratégias que se baseiam exclusivamente em operações matemáticas sobre os valores das avaliações (estratégias utilitárias), tais como Miséria Mínima ou Média Simples, geralmente apresentarão esta propriedade, uma vez que a suposição inicial é de que a todo elemento de I esteja atribuída uma avaliação na faixa de valores utilizada pelo sistema.

Prova para Usuário Mais Representativo:

1. Suponha que existe perfil de entrada $\vec{R}_\epsilon = \{\vec{R}_{\epsilon 1}, \vec{R}_{\epsilon 2}, \dots, \vec{R}_{\epsilon N}\}$, para o qual a estratégia MRU não esteja definida

2. Dessa forma temos duas hipóteses. A1 e A2 falham em estabelecer uma ordenação fraca coletiva para \vec{R}_ε ; H2: Seleção do usuário mais representativo falha em eleger um usuário mais representativo para \vec{R}_ε
3. Se H1, então temos que o usuário MRU foi definido e existe ao menos um par de avaliações r_i e r_j para o qual A1 e A2 não se apliquem. Em outras palavras, r_i e r_j não estabelecem entre si as relações de maior (A1) ou de igual (A2). No entanto, por restrição do problema, r_i e r_j estão contidos no conjunto dos números naturais \mathbb{N} , e assim, estabelecem necessariamente entre si relação de ordem \perp
4. Se H2, então
 - a. Ou $N < 3$ e o sorteio aleatório falha \perp
 - b. Ou $N \geq 3$ e função *medoide()* falha em retornar o usuário MRU (verificar caso a caso)

Considerando o raciocínio anterior, o único ponto em que a estratégia Usuário Mais Representativo está sujeita a não apresentar universalidade está na função *medoide*, onde se é dada a liberdade de definir qualquer função de distância. Trataremos aqui somente da distância Manhattan.

Essa função de distância utiliza o módulo da diferença das avaliações, agindo diretamente sobre os vetores de preferências (\mathbb{N}^*), e resultando também em valores em \mathbb{N} . O subsequente cálculo de $D(u)$ realiza apenas operações de soma ($\sum_{v \in G} d(u, v)$), e, dado que a relação de ordem é compatível com as operações em \mathbb{N} , vale que a função *min()* será capaz de ordenar o conjunto finito $\{u \in G: D(u)\}$, estabelecendo ao menos um elemento mínimo.

3.4.2.2 – Transitividade

O retorno da função de agregação pertence a $\mathcal{OF}(I)$, de forma que seja possível, sem ambiguidade, definir P , sua parte assimétrica e Q sua parte simétrica.

Enquanto a definição anterior se ocupa dos valores de entrada, esta definição exige que a saída seja uma ordenação fraca de I , ou em outras palavras, que esteja definida transitiva-, reflexiva- e completamente para I . De forma a garantir isto, basta que a função

seja capaz de estabelecer uma relação transitiva entre quaisquer três pares de itens. A ocorrência do paradoxo de Condorcet, tratado em 2.1.3.2.1, demonstra que o método de Condorcet não verifica a transitividade.

Prova para Usuário Mais Representativo:

1. Suponha que exista saída de MRU não pertencente a $\mathcal{OF}(I)$, ou seja, para a qual nem P nem Q estejam definidos
2. Dessa forma temos duas hipóteses. H1: Regras A1 e A2 falham em estabelecer tanto P quanto Q para algum subconjunto de I ; H2: Seleção do usuário mais representativo falha em eleger um usuário mais representativo
3. Já verificamos H2 na prova para Universalidade \perp
4. Se H1, então temos que o usuário MRU foi definido e existem itens $i, j, k \in I$ com avaliações $r_i, r_j, r_k \in R$, para os quais as relações P e Q não podem ser estabelecidas nem por A1, nem por A2.
5. No entanto, A1 e A2 são equivalentes em \mathbb{N}^* às relações de maior ($>$) e igual ($=$), definidas inequivocamente para qualquer subconjunto de \mathbb{N}^* , domínio de $R \perp$

Uma estratégia de Recomendação em Grupo incapaz de demonstrar transitividade é a estratégia Média sem Miséria, dado que, para itens que possuam uma avaliação abaixo de certo limiar, a preferência conjunta do mesmo não estará definida, sendo este um exemplo de estratégia não transitiva.

3.4.2.3 – Unanimidade

A função de agregação deve ser tal que, para todo $a, b \in I$, se $r_{u,a} > r_{u,b}$ para todo $u \in G$ então aPb .

A definição, também conhecida como Princípio fraco de Pareto, é bastante intuitiva. Se um item recebe pontuação estritamente maior que outro para cada usuário do grupo, ele deve necessariamente precedê-lo na lista agregada. É importante notar que na definição, aPb é a parte assimétrica de aRb , não admitindo bRa .

Prova para estratégia Usuário Mais Representativo:

1. Suponha que para determinados $a, b \in I$, $r_{u,a} > r_{u,b}$ para todo $u \in G$
2. Suponha $\neg aPb$
3. Por (1), temos que $r_{MRU,a} > r_{MRU,b}$
4. Logo, aPb por A1 e (3)
5. \perp (2 e 4)

Seguindo raciocínio semelhante, não é difícil constatar que as estratégias Ditatorial, Miséria Mínima e Média Simples também atendem a esta propriedade.

3.4.2.4 – Independência das alternativas irrelevantes

Para $\{\vec{R}_1, \vec{R}_2, \dots, \vec{R}_N\} \in \mathcal{R}_{N \times M}$ e $\{\vec{R}'_1, \vec{R}'_2, \dots, \vec{R}'_N\} \in \mathcal{R}'_{N \times M}$, e todo $a, b \in I$ onde $\mathcal{R}_{N \times M}$ e $\mathcal{R}'_{N \times M}$ se distinguem apenas pelas avaliações de u . Se $(r_{u,a} \geq r_{u,b} \Leftrightarrow r'_{u,a} \geq r'_{u,b}) \wedge (r_{u,a} \leq r_{u,b} \Leftrightarrow r'_{u,a} \leq r'_{u,b})$ então $aRb \Leftrightarrow aR'b$.

A formulação acima definitivamente é a mais complexa dentre as propriedades do Teorema de Arrow. As matrizes $\mathcal{R}_{N \times M}$ e $\mathcal{R}'_{N \times M}$ representam as avaliações de um Sistema de Recomendação em dois instantes de tempo, t e t' , sendo $t < t'$. Considere que neste intervalo, apenas o usuário u alterou os valores de seu vetor de preferências, todavia manteve a relação de precedência entre a e b . A propriedade de independência das alternativas irrelevantes garante que a ordenação resultante da agregação das preferências em t (aRb) deverá se manter inalterada em t' ($aR'b$).

A aderência a esta propriedade está intimamente ligada à manipulabilidade de uma estratégia e ao encorajamento à sinceridade. Possuir independência das alternativas irrelevantes dificulta ou impossibilita que um usuário influencie o resultado de maneira favorável a sua real intenção expressando desonestamente suas preferências.

Mostraremos por meio de contraexemplos a não aderência de algumas estratégias. Na Figura 6 e na Figura 7, apenas as avaliações do usuário 3 (R3) variam entre as matrizes da esquerda e direita, enquanto na Figura 8, são as do usuário 1 (R1) que variam. Abaixo de cada tabela se encontram o resultado direto da aplicação da heurística, em seguida a restrição de

independência, relativa aos dois itens observados, mais abaixo, a ordenação fraca resultante, e por último a regra de precedência que é inferida por esta ordenação:

- Média Simples

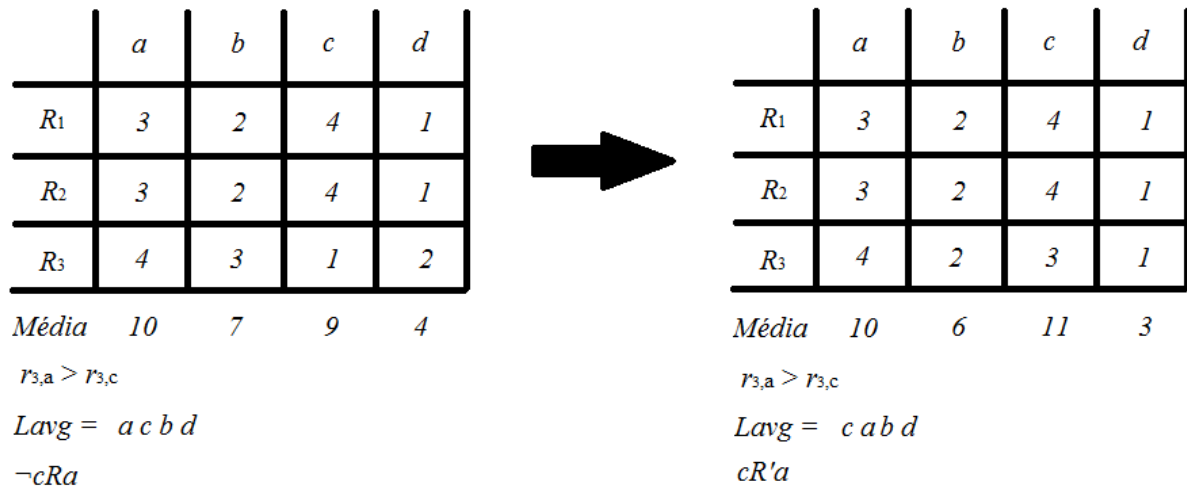


Figura 6 – Contraexemplo para independência das alternativas irrelevantes na estratégia Média Simples

- Miséria Mínima

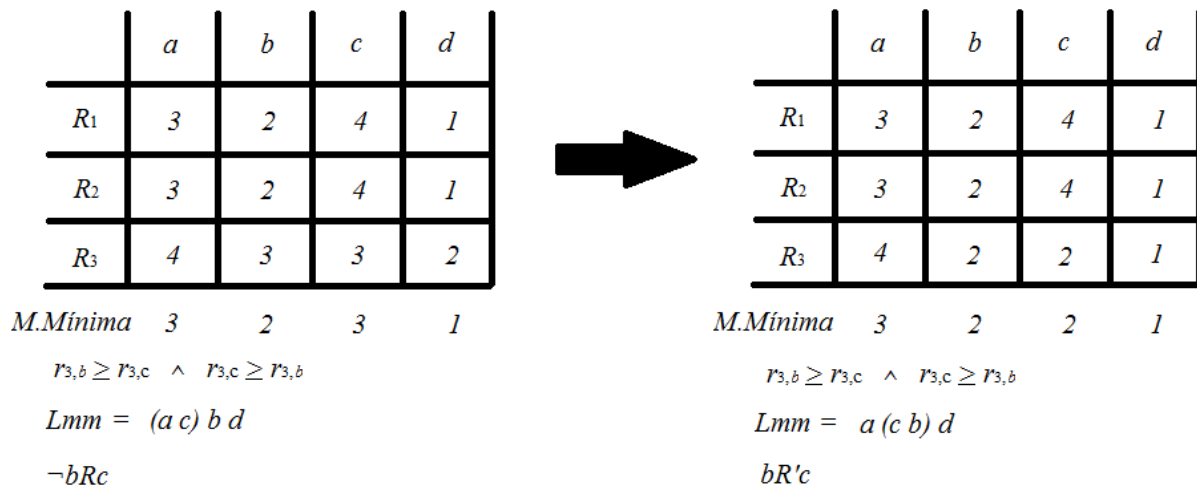


Figura 7 – Contraexemplo para independência das alternativas irrelevantes na estratégia Miséria Mínima

- Ditatorial

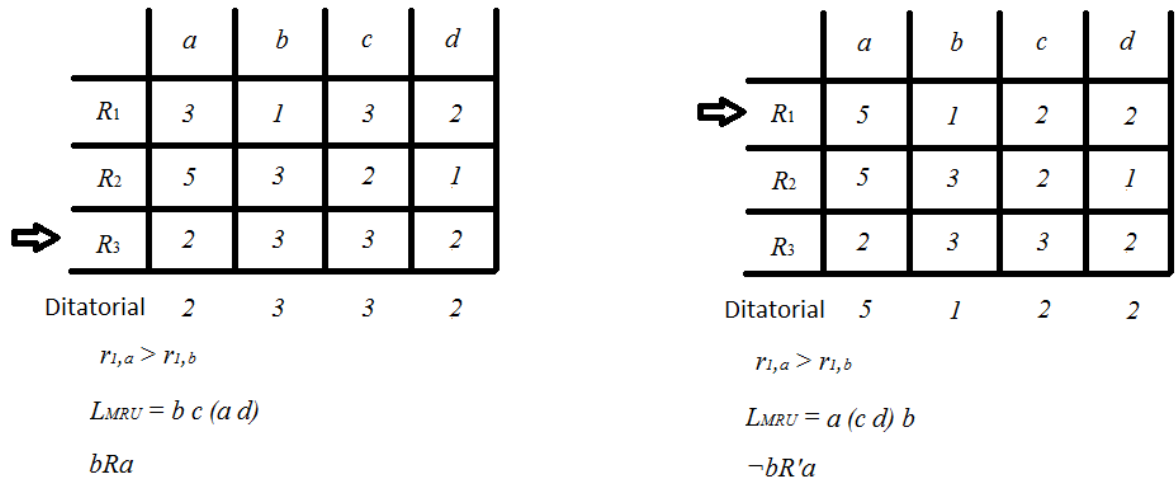


Figura 8 – Contraexemplo para independência das alternativas irrelevantes na estratégia Ditatorial (por sorteio aleatório)

- Usuário Mais Representativo




Figura 9 – Contraexemplo para independência das alternativas irrelevantes na estratégia Usuário Mais Representativo

No contraexemplo para MRU, o cálculo das distâncias dois a dois é apresentado à direita de cada tabela e uma seta ao lado de uma das linhas indica que o usuário foi escolhido como mais representativo pela distância Manhattan. Interessante notar que a propriedade só consegue ser invalidada quando ocorre mudança do usuário mais representativo.

Alegadamente, um usuário que possua interesse em se tornar o mais representativo, conhecendo as preferências dos demais a função de distância, pode tentar construir suas preferências de tal forma que consiga se tornar o novo MRU. No entanto, para que ele aumente suas chances, ele precisa também aproximar suas preferências às dos demais e, em muitos casos, é impossível que ele consiga este resultado sem sabotar suas preferências sinceras. Se menos ambicioso, ele pode tentar apenas aproximar seu perfil a perfis semelhantes de forma a fortalecer um padrão de preferências e tentar eleger outro usuário mais semelhante a si, o que é também razoável.

Dessa forma, a conclusão que podemos chegar após avaliar esta propriedade é a dificuldade e a existência de restrições sob as quais a estratégia MRU pode ser manipulada. Também evidenciamos que, uma vez que os usuários aprendam o funcionamento do mecanismo de escolha, é esperada uma tendência à formação de clusters de usuários com preferências semelhantes.

3.4.2.5 – Não-ditatoriedade

Para todo $u \in N$ e todo $a, b \in I$, existe um perfil $\{\vec{R}_1, \vec{R}_2, \dots, \vec{R}_N\}$ para o qual $r_{u,a} > r_{u,b}$ e bRa .

A propriedade de não-ditatoriedade expressa algo que se espera de uma estratégia justa, o fato de não apresentar viés para qualquer dos usuários do grupo para todas as suas saídas. Uma estratégia ditatorial desestimula a participação, uma vez que não se pode interferir de maneira significativa no resultado final.

A propriedade também considera ditatoriais cenários em que, para qualquer saída, determinado usuário jamais seja prejudicado. Apesar do nome, a estratégia Ditatorial com sorteio aleatório, entendida como todo o processo desde o sorteio, e a estratégia MRU apresentam não-ditatoriedade. Para configurações com dois ou mais usuários em que haja conflito de preferências, existe para ambas a possibilidade de outro usuário, que não o da rodada anterior, ser sorteado. Nesse caso, haverá saída que desagrade alguma vez cada um dos usuários e valerá a não-ditatoriedade.

Um exemplo de estratégia que não atende a esta propriedade é a “Pessoa Mais Respeitada”, mencionada em 3.3, uma vez que nesta estratégia as preferências de um usuário

fixo, escolhido através de informações de contexto, são sempre tomadas como as preferências do grupo.

Os mesmos contraexemplos de independência das alternativas irrelevantes, utilizados para estratégia Ditatorial e Usuário Mais Representativo valem para prova da propriedade não-ditatoriedade. Observem que na grid à esquerda da Figura 8 ou Figura 9, para todos os usuários na tabela, ou a avaliação de a é estritamente maior que a de b , ou é estritamente menor. Podemos concluir da tabela à esquerda, a partir da lista agregada, que bRa , enquanto na grid direita, aRb , e encontramos assim uma contradição com a definição de ditatoriedade, fixado qualquer um dos três usuários.

3.5 – Vantagens e limitações das dimensões de Recomendação em Grupo

Além das propriedades já apresentadas, existem limitações práticas para os cenários onde esta técnica de agregação de preferências pode ser aplicada. Discutiremos algumas a seguir.

3.5.1 – Dinamicidade dos grupos

Sistemas de Recomendação para Grupo são distinguíveis segundo a dinamicidade de formação dos grupos, podendo ser divididos em grupos bem-definidos e grupos efêmeros.

Em sistemas que apresentam grupos efêmeros, os grupos são formados tanto por razões circunstanciais, por exemplo, pelo fato de estarem presentes ao mesmo tempo em um mesmo ambiente, ou então são constituídos por usuários que de alguma forma foram identificados com alguma característica comum pelo sistema.

Este aspecto é positivo, uma vez que a estratégia Usuário Mais Representativo é resistente à mudança do usuário *medóide*, sobretudo se o conjunto de preferências não sofrer constantes mudanças. A mudança do grupo permite outras configurações de preferências, elegendo diferentes usuários para recomendação e tornando, assim, o mecanismo menos previsível.

Em grupos bem-definidos, outras variáveis devem ser consideradas, como a presença de reprise, a frequência de atualização das preferências, etc. Do contrário a estratégia pode se degenerar, apresentando ditatoriedade.

3.5.2 – Conhecimento Mútuo

O nível de conhecimento mútuo oferecido por um sistema interfere diretamente na manipulabilidade do mesmo. Um ponto forte da estratégia MRU está na dificuldade em estimar quem será o usuário mais representativo. Isso se dá porque diferentes funções de distância elegem diferentes usuários. Um exemplo disso é a Figura 10, em que aplicar a distância euclidiana sobre a fatorização SVD e aplicar a distância Manhattan apresentam usuários mais representativos distintos.

$d(u, v) = SVD + euclidiana$ →

$d(u, v) = Manhattan$ →

	i_1	i_2	i_3	i_4	i_5	i_6	i_7	i_8
u_1	3	5	5	3	1	2	3	4
u_2	3	3	2	3	5	4	3	5
u_3	5	3	5	5	3	4	5	1
u_4	3	3	2	3	5	4	3	4

Figura 10 – Critério de seleção do MRU para diferentes funções de distância

Para que um usuário tenha a possibilidade de deduzir o processo de escolha do usuário mais representativo, é essencial que o conhecimento mútuo do sistema seja de no mínimo nível 2 (ciência das preferências dos demais membros). Ainda assim, sem o conhecimento mútuo de nível 3 (ciência do processo de decisão) e, desta forma, desconhecendo a função de distância aplicada, deduzi-la continua sendo uma tarefa bastante complexa.

Em suma, o método proposto é suficientemente robusto à manipulabilidade, característico da variação desta dimensão.

3.5.3 – Tamanho do Grupo

A resistência à variação da dimensão tamanho do grupo é outro ponto forte da proposta deste trabalho. Algumas estratégias como Miséria Mínima e Média sem Miséria rapidamente degeneram com o aumento do tamanho do grupo, uma vez que a probabilidade da ocorrência de avaliações abaixo do limiar estabelecido aumenta conforme o grupo cresce em ambos os casos.

A estratégia Usuário Mais Representativo funciona bem para diferentes tamanhos de grupo, como veremos no 0. Sua capacidade de generalizar o grupo utilizando o usuário

medóide não é afetada por esta dimensão, ainda que a variabilidade da escolha do usuário mais representativo aumente conforme haja mais usuários no grupo.

Inclusive, tudo indica que o aumento do tamanho do grupo fortalece o caráter não-ditatorial da MRU, uma vez que a probabilidade de se escolher um mesmo usuário como usuário mais representativo cai à medida que o número de membros do grupo aumenta

3.5.4 – Frequência de atualizações das preferências

Uma característica de Sistemas de Recomendação que deve ser considerada, mas que não constitui por si uma dimensão, é a frequência com que as preferências individuais são atualizadas. Um sistema com poucas atualizações, seja pela estagnação do conjunto de itens ou pela baixa participação, reduz a variabilidade na seleção do usuário mais representativo.

De toda forma, a escassez de atualizações do conjunto de preferências afeta de maneira geral as estratégias de recomendação em grupo, também no que se refere à variabilidade da recomendação. Torna-se difícil recomendar itens baseando-se em pouca informação a respeito dos usuários, ou então surpreender o grupo, uma vez esgotadas as opções inéditas de itens.

Em particular, a estratégia MRU sofre o aumento de seu caráter ditatorial uma vez que a baixa frequência de atualizações reduz significativamente as chances de alternância do usuário mais representativo, podendo inclusive torna-lo estacionário.

Capítulo 4 – Coleta de preferências: Filmes em Grupo

Nesta sessão será detalhada a construção da ferramenta “Filmes em Grupo”, protótipo utilizado neste trabalho com a finalidade de coletar dados de Recomendação em Grupo, de usuários reais, e replicar alguns experimentos conduzidos por artigos em que se prevê a validação da recomendação com grupos de usuários reais.

Muitos dos experimentos voltados para a recomendação em grupo documentados até o momento possuem uma característica bastante negativa, que é a de serem pouco generalizáveis. Costumeiramente, cada autor busca atacar um nicho muito específico, com variáveis e mecanismos que só fazem sentido em determinado domínio. A base de dados gerada também tende a ser pouco reaproveitável, pois a maneira como a informação é coletada e, principalmente, como a recomendação é aceita pelo grupo, depende de critérios adotados, os quais são bastante inflexíveis a adaptações.

4.1.1 – Objetivos dos experimentos

Podemos dizer que foram dois os principais propósitos dos experimentos desta seção: reproduzir os resultados obtidos em outros artigos em nosso próprio Sistema de Recomendação para Grupo, mas também contribuir com a construção de uma base de dados para testes voltados à Recomendação em Grupo, suficientemente genérica e flexível, para o uso livre da comunidade acadêmica.

Os experimentos foram separados em três etapas que serão tratadas em detalhes a seguir, cada uma com objetivos distintos:

Etapa 1) Usuários explicitam suas preferências a respeito dos itens na base

Etapa 2) Usuários são agrupados de acordo com a informação obtida anteriormente em grupos de tamanhos e afinidade entre membros variáveis. Recebem a recomendação em grupo, explicitam individualmente sua satisfação, e são levados a uma etapa de negociação na qual debatem em conjunto sobre as divergências de opinião acerca da recomendação recebida.

Etapa 3) Independente das anteriores, nesta é realizada uma coleta de dados mais completa, visando o reuso dos dados.

Além da descrição do sistema de coleta de dados, será feito um balanço crítico dos resultados obtidos em cada etapa, bem como a razão para o sucesso ou fracasso de cada abordagem.

4.1.2 – Etapa um: Coleta de Preferências

Como já mencionado, um ponto comum a Sistemas de Recomendação para Grupos é a necessidade de adquirir de antemão a informação sobre as preferências de cada usuário, seja pela coleta explícita, seja de maneira implícita, através da interação entre usuário e sistema.

Dadas as alternativas, a decisão tomada foi a de seguir a mesma linha de outro trabalho já consolidado na área, utilizando-o também como parâmetro de comparação. O trabalho a que nos referimos é o de (AMER-YAHIA *et al.*, 2009), que utiliza uma metodologia comum a outros autores, tais como (DE CAMPOS *et al.*, 2007) e (O’CONNOR *et al.*, 2002). A obtenção das preferências é realizada de maneira explícita, completando-se as lacunas de informação com a aplicação de Filtro Colaborativo.

O experimento de Amer-Yahia utiliza a união de dois conjuntos de filmes como seus itens, que foram importados do sistema *MovieLens*¹ segundo o seguinte critério: um conjunto é constituído pelos 40 filmes mais avaliados e o segundo pelos 20 filmes com maior desvio padrão de notas, dentre os 200 filmes mais avaliados (mesmo que já pertençam ao conjunto anterior). De forma a reduzir qualquer tendenciosidade que pudesse advir da escolha dos filmes, inicialmente utilizamos o mesmo critério e selecionamos os mesmos filmes para integrar nossa base. A faixa de avaliações também foi mantida utilizando-se os valores de 0 a 5, onde 0 denota que o filme não foi avaliado. Também foi seguida a orientação de exigir que um mínimo de 30 filmes fosse avaliado para que o candidato estivesse elegível à etapa seguinte.

Os participantes de nosso experimento, apelidado por “Filmes em Grupo”, foram voluntários, sem qualquer forma de remuneração, o que destoa também do artigo de Amer-Yahia, que utilizou o recurso *Amazon Mechanical Turk*². Este recurso fornece mão-de-obra sob demanda, que são remunerados para executar o que é chamado de “Human Intelligence

¹ Disponível em: <<http://movielens.umn.edu/>>

² Disponível em <<https://www.mturk.com>>

Tasks (HIT's)". Este fator influenciou de maneira expressiva no resultado da segunda etapa, e será revisto mais à frente.

4.1.2.1 – Telas do sistema

Na tela inicial do sistema, durante a primeira etapa, o usuário era apresentado a uma mensagem de “Boas Vindas” onde encontrava um breve resumo do que constituía a etapa e a opção para autenticar-se ou criar uma nova conta, conforme ilustrado na Figura 11.

A imagem mostra a interface de usuário da página de boas vindas do sistema "Filmes em grupo". No topo, há um cabeçalho com o logo de uma flor verde e o título "Filmes em grupo". Abaixo, o título "Boas Vindas" é seguido por uma mensagem de boas vindas e duas etapas do experimento. O usuário é informado de que, ao se cadastrar, estará contribuindo para a dissertação de Pedro Rougemont. Há duas opções de login: "Já me cadastrei" (selecionada) e "Ainda não estou cadastrado". Abaixo, há campos de entrada para "Usuário" e "Senha", com instruções para digitar o nome de usuário e a senha. Um botão "Entrar" está localizado abaixo dos campos.

Figura 11 – Imagem da tela de boas vindas do Filmes em Grupo

No caso do voluntário não possuir cadastro, uma série de informações deveria ser fornecida ao sistema, sendo de particular importância o apelido, uma conta autêntica de e-mail usada para validação, e uma imagem de avatar, que melhor retratasse o participante, conforme ilustra a Figura 12.

Boas Vindas

Olá! Seja bem vindo ao experimento "Filmes em Grupo". Daqui em diante, você será guiado em duas etapas distintas:

- Neste primeiro momento, será solicitada sua opinião a respeito de alguns filmes;
- Em um momento posterior será convidado novamente ao site para interagir com outros usuários.

Ao se cadastrar neste site e participar das duas etapas deste experimento, estará contribuindo para a dissertação de Pedro Rougemont.

Você já criou sua conta?

- Já me cadastrei
- Ainda não estou cadastrado

Usuário *

Espaços são permitidos; pontuação não é permitida exceto pontos, hífens, apóstrofos e sublinhados.

Endereço de email *

Um email válido. Todos os emails do sistema são enviados para este endereço. O email não é visível para o público e será usado apenas se você precisar recuperar a sua senha ou desejar receber notícias ou notificações por email.

Senha *

Qualidade da senha: _____

Confirme a senha *

Digite uma senha para a nova conta nos dois campos.

Foto

Select an avatar *



Your virtual face or picture.

[Criar nova conta](#)

Figura 12 – Tela para cadastro de novo usuário do Filmes em Grupo

Uma vez autenticado, o usuário era então apresentado a uma grade que listava dez filmes por vez e continha informações que pudessem auxiliá-lo a avaliar cada filme, como títulos em inglês, em português, ano de lançamento, cartaz, trailer, etc.. Abaixo de cada síntese, o usuário deveria avaliar o filme a partir da atribuição de estrelas, numa gradação de uma (mínimo) a cinco (máximo), sendo que uma estrela significava que o filme o desagradava completamente, enquanto cinco significava que o filme o agradava completamente.


Filmes em grupo
Minha conta Sair



Avalie alguns de nossos filmes

Muito bem, o próximo passo trata-se de avaliar pelo menos 30 dos 70 filmes listados a seguir, de acordo com seu gosto pessoal na escala de 1 a 5 estrelas.

Muito provavelmente você não terá assistido a todos os filmes. Tente emitir um parecer aproximado para os filmes que poderiam despertar seu interesse, assistindo aos trailers.

Seja sincero em suas avaliações pois o sistema levará em conta que estas são suas preferências reais.

Um Sonho de Liberdade (1994)
The Shawshank Redemption (1994)

Two imprisoned men bond over a number of years, finding solace and eventual redemption through acts of common decency.

+ Detalhes (IMDb)

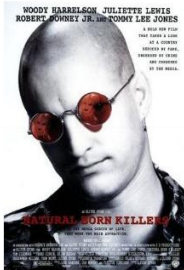


Trailer:
<http://www.imdb.com/video/screenplay/vi882809625/>
 Avaliação:
 ★★★★★

Assassinos por Natureza (1994)
Natural Born Killers (1994)

Two victims of traumatized childhoods become lovers and psychopathic serial murderers irresponsibly glorified by the mass media.

+ Detalhes (IMDb)



Trailer:
<http://www.imdb.com/video/screenplay/vi3902275865/>
 Avaliação:
 ★★★★★

As Estrelas de Henrietta (1995)
The Stars Fell on Henrietta (1995)

The setting is early America during the oil boom. An elderly, down on his luck 'oil man', Mr...

+ Detalhes (IMDb)



V de Vingança (2005)
V for Vendetta (2005)

"A shadowy freedom fighter known only as ""V"" uses terrorist tactics to fight against his totalitarian society. Upon rescuing a girl from the secret police, he also finds his best chance at having an ally."

+ Detalhes (IMDb)



Figura 13 – Tela de captura de preferências da primeira etapa do Filmes em Grupo

73

4.1.2.2 – Balanço geral

Pouco tempo depois do lançamento do sistema, os usuários reportaram insatisfação com o conjunto de filmes selecionados para avaliação, a ponto de tornar trabalhosa ou impeditiva a tarefa de avaliar trinta dentre quarenta filmes. Em função do critério usado para importação dos dados, que priorizou o número de avaliações recebidas na base *Movielens*, o resultado foi que lançamentos mais antigos, em particular os anteriores à primeira metade dos anos 90, foram escolhidos.

A época de lançamento dos filmes é, portanto, uma informação de contexto imprescindível de ser considerada. De forma a remediar este problema sem perder a informação já coletada, foram adicionados mais 30 títulos recentes à base, advindos do portal *Internet MovieDatabase*³, totalizando um conjunto de 70 filmes. Com este acréscimo, os usuários se mostraram confortáveis em cumprir a meta.

4.1.2.3 – Números da etapa

A tabela a seguir apresenta algumas características referentes a esta etapa:

Tabela 5 – Índices da primeira etapa

Índice	Valor
Total de usuários cadastrados nesta etapa	96
Candidatos válidos (aprovados para próxima etapa)	45
Total de avaliações	2105
Avaliações de candidatos válidos	1443
Média das avaliações válidas	3,466
Desvio padrão das avaliações válidas	1,342
Média dos desvios padrão por usuário	1,213
Média dos desvios padrão por filme	0,9046

³ Disponível em: <<http://www.imdb.com>>

A informação que mais chama a atenção é a do número de candidatos capazes de completar a primeira etapa, que ficou abaixo da metade dos cadastrados. Isto pode ser explicado tanto pela baixa popularidade dos primeiros filmes escolhidos no primeiro momento, quanto pela restrição de um mínimo de 30 avaliações.

4.1.3 – Etapa dois: Recomendação em grupo e resolução de conflitos

Os dados recolhidos na primeira etapa foram então processados, servindo de entrada para a etapa dois, na qual foi realizada a separação dos usuários em grupos. De acordo com o experimento de (AMER-YAHIA *et al.*, 2009), dois fatores são considerados influentes na formação dos grupos que receberão recomendações: o tamanho do grupo e sua coesão. De forma a testar o desempenho de diferentes estratégias de agregação de preferências, a base haveria de ser dividida em grupos de cardinalidade e coesão dos membros variável. A metodologia escolhida para fazer essa separação de forma homogênea foi:

1. Calcular a matriz de similaridade S entre usuários
2. Escolher clusters de usuários, de tamanho pré-fixado, que componham grupos de alta coesão, totalizando metade de todos os usuários.
3. Com procedimento semelhante, formar grupos de baixa coesão com o restante dos usuários.
4. Preencher as lacunas da matriz de avaliações R com valores obtidos pela aplicação de Filtro Colaborativo.
5. Para cada estratégia, separar quatro grupos: dois grupos de alta e dois grupos de baixa coesão, sendo um grande e um pequeno para cada tipo.
6. Gerar todas as listas de recomendação.

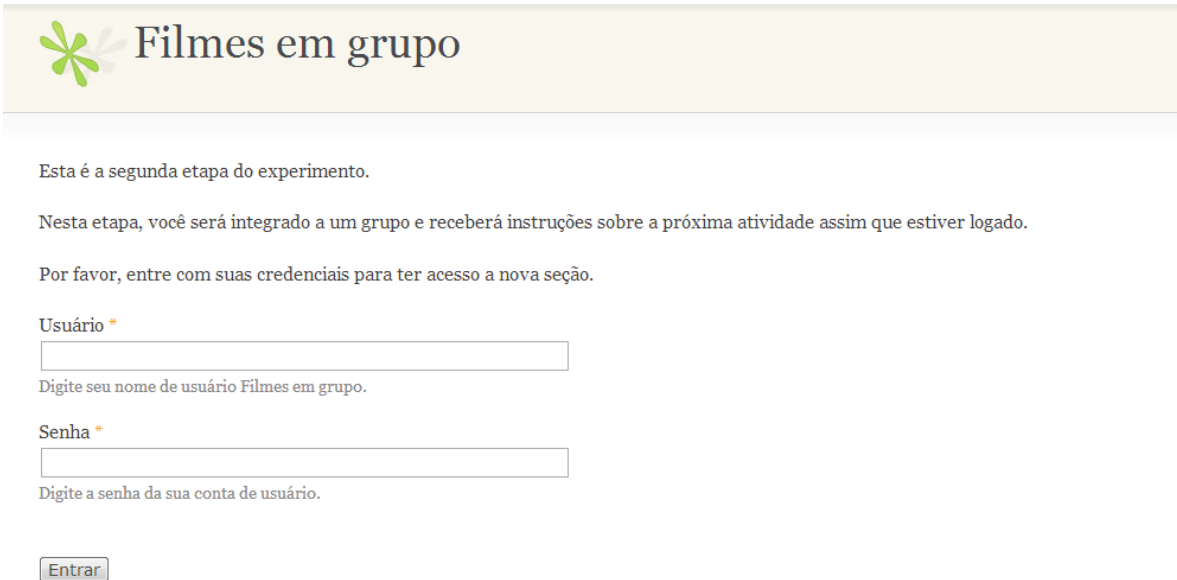
As estratégias escolhidos para o teste foram:


- Média
- Miséria Mínima
- Média Ponderada por Participação (onde o peso da opinião de um usuário na recomendação é proporcional ao número global de avaliações individuais)

Podemos comparar os resultados da Média e Miséria Mínima com o artigo de Amer-Yahia, visto que as mesmas estratégias foram utilizadas em ambos os experimentos. Após o processamento, a informação referente aos grupos e suas recomendações respectivas foram transferidas para o sistema web e novas telas foram desenvolvidas para este novo tipo de interação.

4.1.3.1 – Telas do sistema

Os candidatos que se qualificaram na etapa anterior, e que portanto pertencem a algum dos grupos já definidos foram convidados a participar da segunda etapa. A nova tela de boas vindas apresentava somente a opção de autenticação, direcionando-os em seguida para a tela de instruções.



 **Filmes em grupo**

Esta é a segunda etapa do experimento.

Nesta etapa, você será integrado a um grupo e receberá instruções sobre a próxima atividade assim que estiver logado.

Por favor, entre com suas credenciais para ter acesso a nova seção.

Usuário *

Digite seu nome de usuário Filmes em grupo.

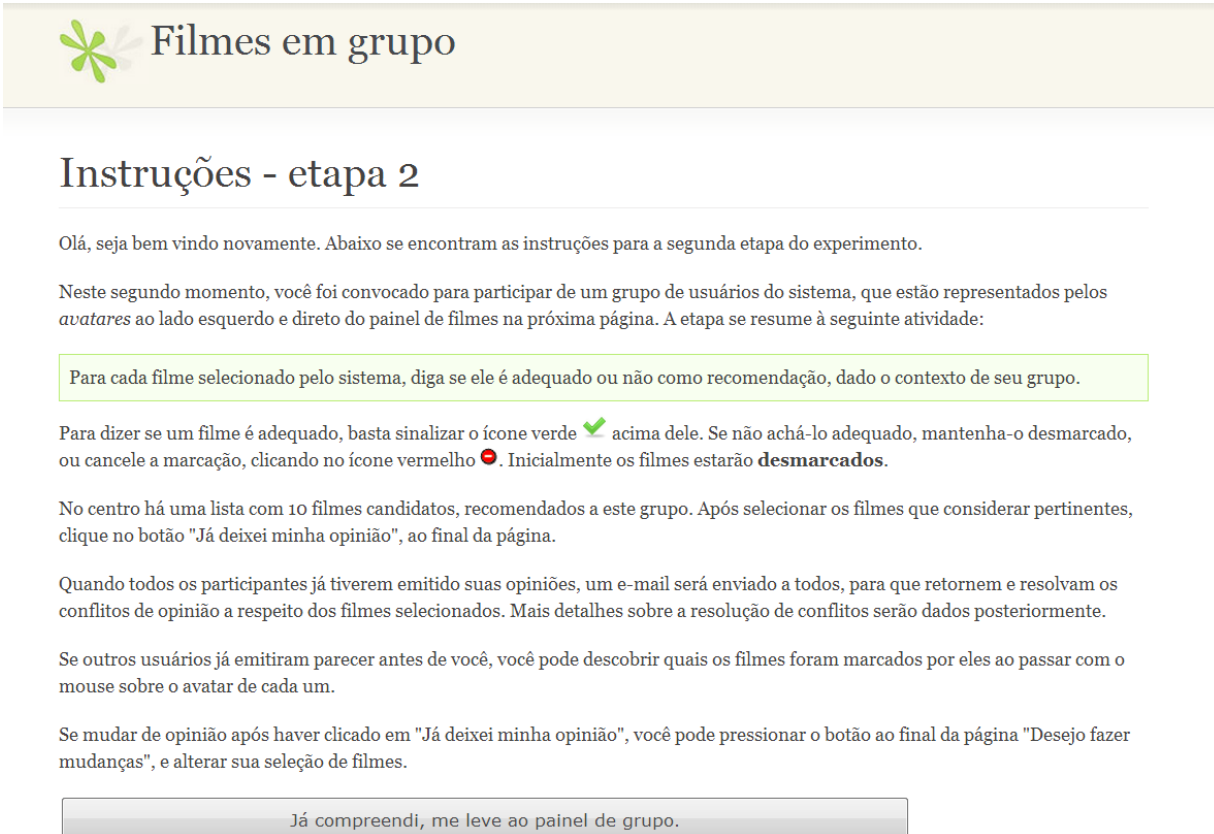
Senha *


Digite a senha da sua conta de usuário.

Figura 14 – Tela inicial da segunda etapa do Filmes em Grupo

4.1.3.1.1 – Primeiro momento: aprovação da recomendação recebida

Nas instruções, o usuário era orientado a qualificar cada um dos dez filmes apresentados, classificando-os como recomendações pertinentes ou não, dado o contexto de seu grupo. Esta foi a mesma questão formulada por (AMER-YAHIA *et al.*, 2009) em seus experimentos. Neste caso, os usuários também eram informados da continuidade da etapa em um segundo momento, após a conclusão deste processo por todos os membros do grupo.





 Filmes em grupo

Instruções - etapa 2

Olá, seja bem vindo novamente. Abaixo se encontram as instruções para a segunda etapa do experimento.

Neste segundo momento, você foi convocado para participar de um grupo de usuários do sistema, que estão representados pelos *avatars* ao lado esquerdo e direito do painel de filmes na próxima página. A etapa se resume à seguinte atividade:

Para cada filme selecionado pelo sistema, diga se ele é adequado ou não como recomendação, dado o contexto de seu grupo.

Para dizer se um filme é adequado, basta sinalizar o ícone verde  acima dele. Se não achá-lo adequado, mantenha-o desmarcado, ou cancele a marcação, clicando no ícone vermelho . Inicialmente os filmes estarão **desmarcados**.

No centro há uma lista com 10 filmes candidatos, recomendados a este grupo. Após selecionar os filmes que considerar pertinentes, clique no botão "Já deixei minha opinião", ao final da página.

Quando todos os participantes já tiverem emitido suas opiniões, um e-mail será enviado a todos, para que retornem e resolvam os conflitos de opinião a respeito dos filmes selecionados. Mais detalhes sobre a resolução de conflitos serão dados posteriormente.

Se outros usuários já emitiram parecer antes de você, você pode descobrir quais os filmes foram marcados por eles ao passar com o mouse sobre o avatar de cada um.

Se mudar de opinião após haver clicado em "Já deixei minha opinião", você pode pressionar o botão ao final da página "Desejo fazer mudanças", e alterar sua seleção de filmes.

Já compreendi, me leve ao painel de grupo.

Figura 15 – Instruções da segunda etapa do Filmes em Grupo

A seguir, a tela do grupo era apresentada, quando, pela primeira vez, o usuário tomava ciência de outros participantes. Ao centro ficavam dispostos em duas colunas os dez filmes que constituíam a lista recomendada para o grupo; distribuídos nas laterais, os avatares dos participantes; e, ao final, um botão para confirmar que sua opinião já havia sido expressa (Figura 16).

O usuário então deveria clicar em um botão no formato de “V”, em cor cinza que se localizava acima dos filmes, indicando que a recomendação daquele filme ao grupo foi















aprovada por ele. Após pressionado, o botão passava a ter o formato de um sinal de menos (-), em vermelho, permitindo o cancelamento de sua aprovação.

Filmes em grupo
Minha conta Sair

Seu Grupo

Leia novamente as instruções para a segunda etapa

Filmes Recomendados

 admin	 De Volta para o futuro (1985)	 Coração Valente (1995)	 helder
 mavapa	 Cisne Negro (2010)	 Laranja Mecânica (1971)	 uvapotta
	 Cidade de Deus (2002)	 Contagem Regressiva (1994)	
	 A Promessa (1995)	 City Hall - Conspiração no Alto Escalão (1996)	
	 Copycat - A Vida Imita a Morte (1995)	 Três Amigas e uma Traição (1995)	

Já deixei minha opinião

Figura 16 – Tela para aprovação dos itens recomendados ao grupo

Além do nome e avatar dos demais participantes, o usuário também contava com a informação das recomendações de filmes já aprovadas pelos demais. Isto se dava por intermédio de um contador localizado acima de cada filme, exibido somente após pressionar-

se o botão “Já deixei minha opinião”. Nessa ocasião, a mudança dos filmes escolhidos ficava bloqueada para aquele usuário (Figura 17).

Filmes em grupo
Minha conta Sair

Seu Grupo

Leia novamente as instruções para a segunda etapa

Filmes Recomendados

Usuário	Recomendações	Filme	Ano
admin	2	O Senhor dos Anéis: O Retorno do Rei	2003
boleta	2	De Volta para o futuro	1985
fvianna	2	Matrix	1999
	2	Forrest Gump, o Contador de Histórias	1994
	1	Seven - Os Sete Crimes Capitais	1995
	2	Gladiador	2000
	2	O Rei Leão	1994
	1	Cisne Negro	2010
	2	Toy Story	1995
	1	Um Sonho de Liberdade	1994

Mudei de opinião

Figura 17 – Contagem de recomendações aprovadas por membros do grupo


De forma a indicar aos demais participantes que os outros usuários já tinham feito suas avaliações, o sistema exibia ao lado de seu nome, um pequeno ícone na forma de *checkbox*. Se

a qualquer momento o usuário desejasse mudar suas escolhas, bastaria pressionar o botão “Mudei de opinião”. A função dessa possibilidade de mudança de estado era a de garantir que usuários pudessem descobrir a impressão parcial dos demais, influenciando assim suas próprias decisões. Ainda que reduzida, se comparada a experimentos com grupo presenciais, a informação mútua fornecida nesta etapa do experimento é semelhante a cenários em que os participantes do grupo são desconhecidos entre si, mas possuem ciência do grupo e das preferências dos demais participantes.

No momento em que todos os participantes já haviam deixado suas impressões, o sistema então calcula recomendações que tenham ficado em estado conflituoso. Uma recomendação não estava em conflito se ela foi aprovada por todos, ou rejeita por todos. Se ao menos um membro emitiu parecer divergente dos demais, este filme foi classificado como “em conflito de opinião”, passando a constar na tela de resolução de conflitos.

4.1.3.1.2 – Segundo momento: resolução de conflitos

Após o cálculo da lista de filmes conflituosos, o sistema enviou um e-mail convidando os participantes a retornarem, apresentando novas instruções quanto a como proceder para a resolução de conflitos.



The screenshot shows a web interface for 'Filmes em grupo'. At the top left is a green star logo and the text 'Filmes em grupo' with links for 'Minha conta' and 'Sair'. The main heading is 'Instruções - resolução de conflitos', with 'Ver' and 'Editar' buttons. The instructions text reads: 'Todos os participantes já emitiram sua primeira opinião sobre as recomendações feitas ao grupo, agora é o momento da resolução de conflitos, onde membros do grupo podem discutir a respeito das recomendações feitas e mudar ou não seu parecer. Logo abaixo de cada filme, estão a contagem de votos contra e a favor, seu voto, e as opiniões dadas favoráveis e contra aquele filme pelos demais usuários do grupo. Se alguma opinião convence-lo, poderá a qualquer momento mudar seu voto. Se o consenso for atingido (todos os votos negativos ou positivos), a discussão para aquele filme se encerra. Esta etapa se encerra caso não haja mais conflitos sobre recomendações, ou quando a etapa for encerrada mesmo que ainda hajam conflitos (data será avisada previamente por e-mail).' At the bottom is a button that says 'Já compreendi, me leve ao painel de resolução de conflitos.'

Figura 18 – Instruções para resolução de conflitos

A ideia deste segundo momento não é tratada em (AMER-YAHIA *et al.*, 2009), mas está presente em diferentes formas em outros sistemas, como em (MCCARTHY *et al.*, 2006a). Neste segundo, se distinguem as recomendações reativas e proativas. As primeiras são baseadas inteiramente em preferências individuais, enquanto as últimas são feitas após o recebimento de críticas dos usuários. Nesta etapa não foi implementado um modelo de *Críticas*, pois o objetivo principal foi o de comparar a aceitação e a mudança de opinião dos membros.

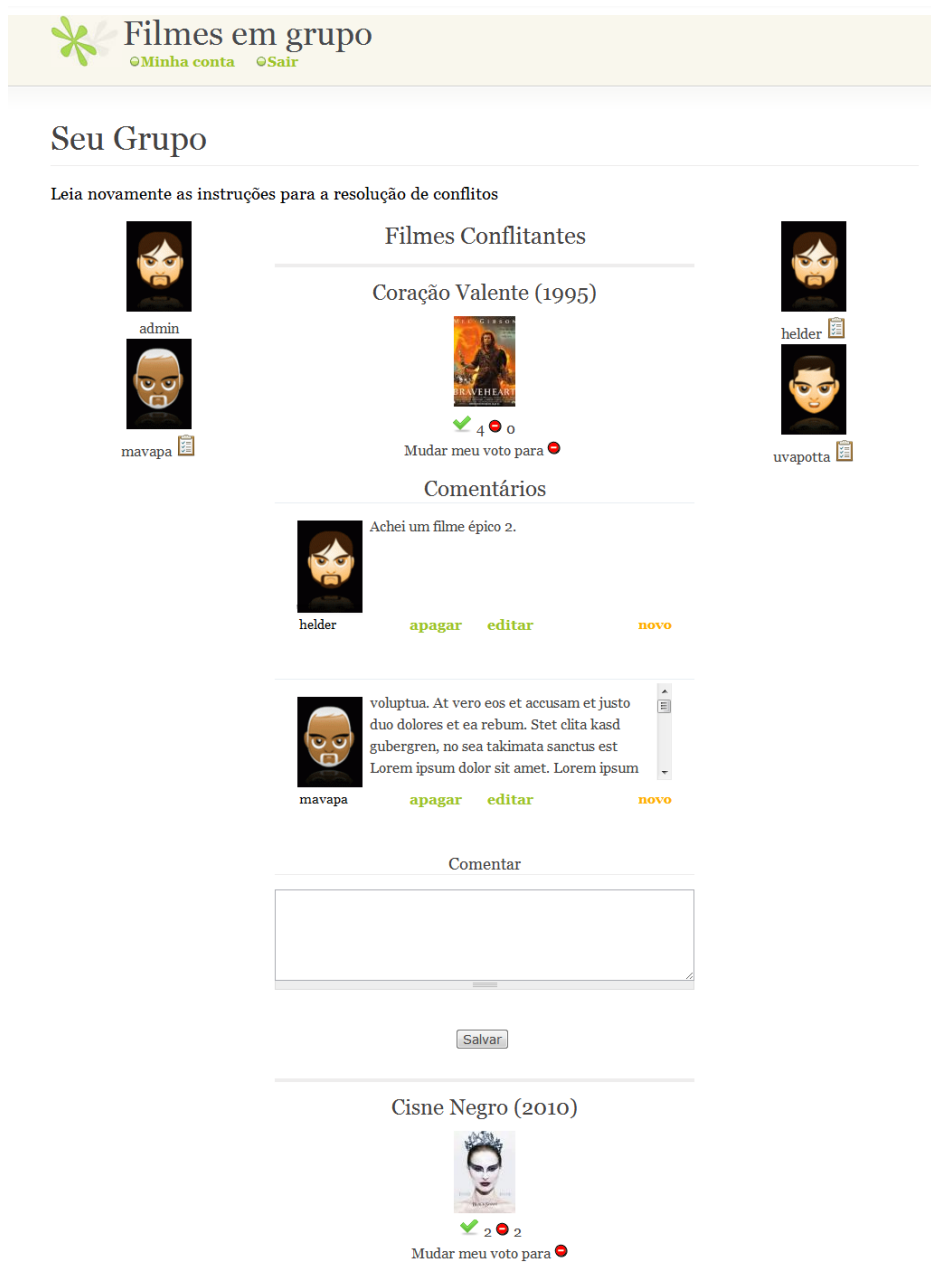


Figura 19 – Tela de resolução de conflitos

A tela de resolução de conflitos exibia novamente os participantes do grupo nas laterais, e ao centro ficavam dispostos em coluna única os filmes conflitantes. Constando título, cartaz, contagem de votos favoráveis e desfavoráveis à recomendação, e uma opção para mudança de voto. Além disso, abaixo de cada filme havia uma caixa de texto para que os usuários pudessem deixar seus comentários (exibidos em ordem cronológica abaixo do filme comentado).

Filmes conflitantes que atingissem o consenso eram retirados da listagem principal, e um grupo que atingisse consenso em todas as recomendações encerrava antecipadamente a etapa. Porém este não era o único critério para o fim de etapa, que foi encerrada por critério de tempo, após três meses no ar.

4.1.3.2 – Balanço Geral

Um grande problema encontrado nesta etapa foi o ausência de retorno dos participantes da etapa anterior. Muitos dos grupos não chegaram sequer a concluir o primeiro momento da etapa, o que reduziu bastante a quantidade de resultados. Este problema também foi relatado em (AMER-YAHIA *et al.*, 2009), em que mesmo com uma maior recompensa oferecida para usuários de fases anteriores, foi necessário a adição artificial de participantes que deveriam fingir serem os membros faltantes, medida não adotada aqui.

4.1.3.3 – Números da Etapa

Alguns dados sobre esta etapa podem ser verificados na Tabela 6.

Tabela 6 – Números da segunda etapa do Filmes em Grupo

Índice	Valor
Tamanho médio dos grupos pequenos	3
Tamanho médio dos grupos grandes	4,33
Total de usuários cadastrados na etapa	45
Total de usuários que participaram da etapa	25
Recomendações aprovadas pelos usuários	186
Total de grupos	12
Grupos que chegaram à resolução de conflitos	7
Comentários postados na resolução de conflitos	34
Recomendações recusadas após resolução de conflitos	6
Recomendações aprovadas após resolução de conflitos	26
Grupos que chegaram ao consenso	1

Em particular as características do grupo que atingiu o consenso foram:

- Grupo Coeso
- Estratégia de Agregação por Média
- Tamanho: 4 pessoas

Além dos resultados já descritos, também foi possível utilizar os dados dos participantes que emitiram parecer sobre as recomendações durante a segunda etapa (chegando ou não à resolução de conflitos). A fim de medir a eficiência das três estratégias, utilizamos a métrica Ganho Acumulativo Descontado Normalizado (nDCG). A única consideração é a de que usuários que não emitiram parecer sobre recomendações foram desconsiderados para efeito de cálculo, não contribuindo assim na normalização. Os resultados podem ser observados na tabela a seguir.




Gráfico 1 - Valor médio da métrica nDCG para diferentes tamanhos de grupo

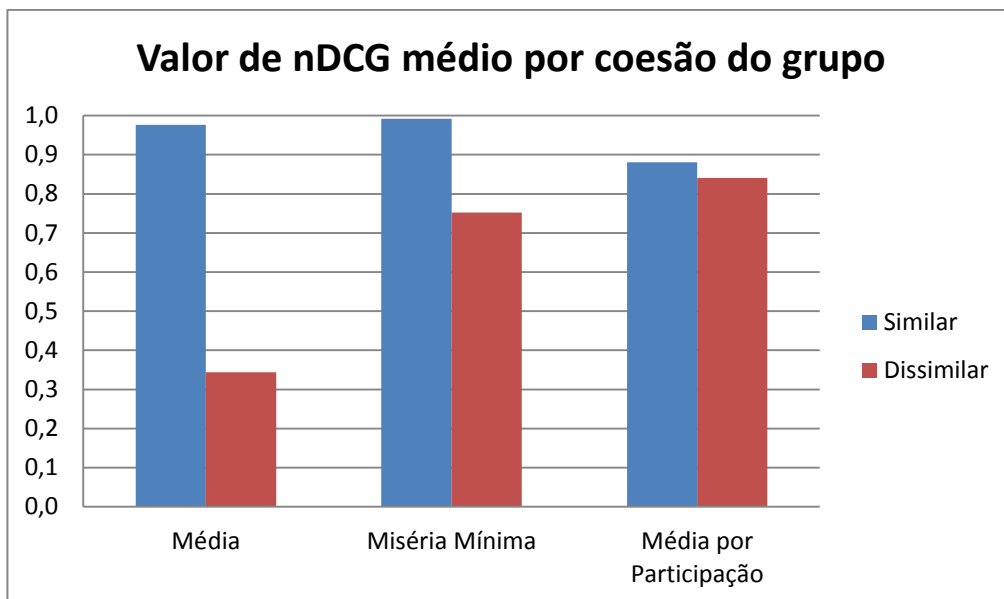


Gráfico 2 – Valor médio da métrica nDCG para grupos de coesão distinta

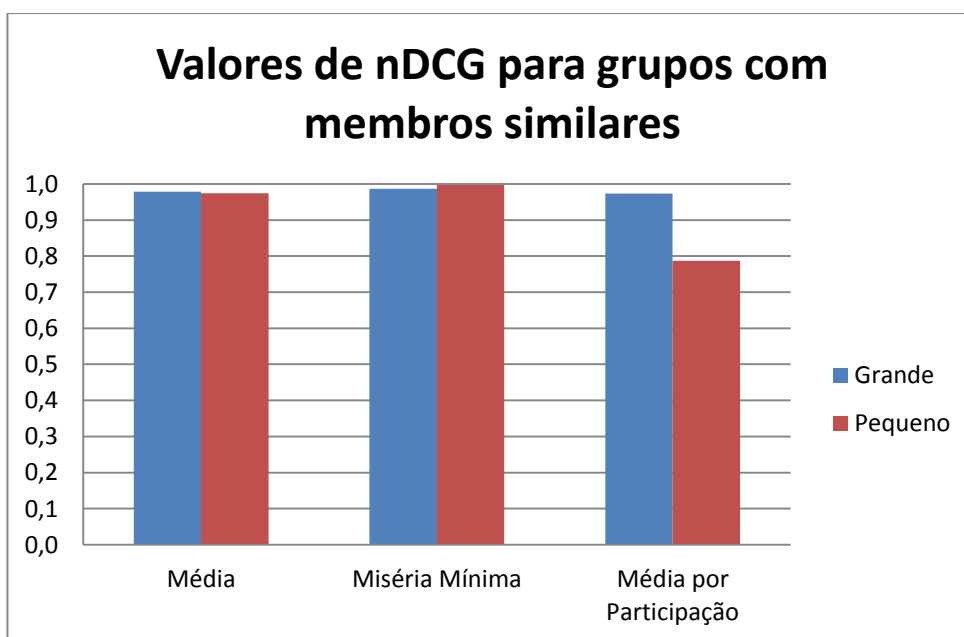


Gráfico 3 – Valores de nDCG por tamanho de grupo, fixada alta similaridade entre membros




Gráfico 4 – Valores de nDCG por tamanho de grupo, fixada alta dissimilaridade entre membros (participação insuficiente para este cenário)

Conferimos que tanto o tamanho dos grupos quanto a similaridade de seus membros influenciam no sucesso de uma estratégia, ainda que não necessariamente sejam dimensões independentes, como nos leva a crer o Gráfico 3.

Além disso, podemos observar que a estratégia “Média por Participação” apresentou estabilidade no valor de nDCG para os diferentes cenários, ainda que esta não tenha melhor desempenho na maioria dos casos. Outra característica interessante foi a obtenção de melhores resultados com grupos grandes, comportamento inverso das demais estratégias testadas.

Uma última observação é a de que os gráficos referentes às estratégias “Média” e “Miséria Mínima” contidos no artigo (AMER-YAHIA *et al.*, 2009) destoam dos resultados deste experimento, visto que, para as duas estratégias e cenários tratados no artigo, a mudança foi bem mais significativa do que as retratadas aqui. Uma possível razão para a diferença também se atribui a baixa participação na segunda etapa, comprometendo inclusive a avaliação de grupos dissimilares em sua totalidade.

4.1.4 – Etapa três: Coleta direcionada para Recomendação em Grupo

A terceira etapa surgiu da necessidade de obter um conjunto de dados que pudesse ser reutilizado em experimentos posteriores. Uma vez que se encontra grande dificuldade em conduzir experimentos de recomendação em grupo conforme os parâmetros requeridos (duas etapas, requerer um mínimo de avaliações para prosseguir à etapa seguinte, etc.).

O convite a usuários para uma segunda rodada de interação foi entendida como inadequada, já que, para cada nova rodada de experimentos, haveria a necessidade de uma segunda coleta de dados, a fim de validar o experimento. Dessa forma, planejamos uma forma de obter de imediato a informação necessária para treinar e em seguida validar recomendações. Inevitavelmente, algumas dimensões da Recomendação em Grupos foram prejudicadas por esse processo.

Primeiramente, o conhecimento mútuo foi desconsiderado, uma vez que a formação dos grupos se dá depois que os usuários emitiram individualmente suas avaliações, e estes não tem ciência desta divisão. Além disso, formas de agregação que considerem alguma informação de contexto (relações entre membros, dados censitários, etc.) não poderão ser utilizadas.

A última questão a ser considerada seria então como validar o modelo de preferências construído, já que não seria possível contar com um novo parecer dos usuários. Uma opção seria aplicar Validação Cruzada na base de preferências, estabelecendo uma fração da base para teste. Esta inclusive foi a proposta sugerida por (BALTRUNAS *et al.*, 2010).

Uma alternativa considerada foi a de requisitar que os participantes ordenassem todos os filmes da base, de forma a colocar seus preferidos no topo e os que detestassem ao final. Para tal, chegou a ser desenvolvida uma interface que permitiria a ordenação dos filmes, mas a ideia foi descartada em seguida, por ser considerada uma tarefa cansativa e de pouco apelo a voluntários.

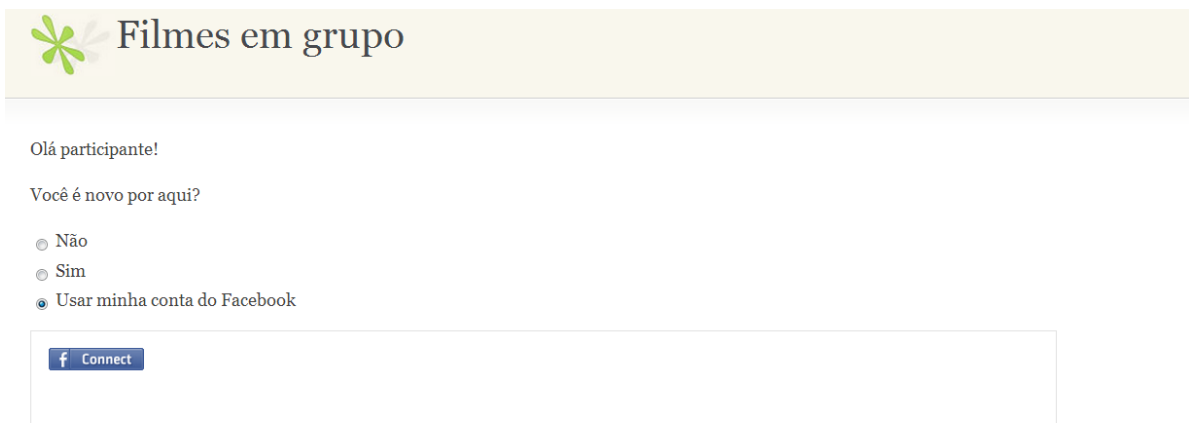
A ideia final surgiu quando decidimos distinguir filmes que o usuário havia visto de fato, daqueles que não assistiu. Consideramos que a opinião do usuário sobre um filme desconhecido denota a sua receptividade para uma recomendação, logo propomos a criação de quatro possíveis formas de um usuário exprimir suas preferências:

- Filmes que o usuário assistiu, pontuados de 1 a 5 estrelas
- Filmes que o usuário não assistiu, porém gostaria de ver
- Filmes que o usuário não assistiu, e não gostaria de assistir
- Filmes que o usuário não assistiu e é indiferente

Com esta metodologia, é possível separar as avaliações a respeito dos filmes que o usuário já viu, utilizada para construir o modelo de preferências de grupo, das avaliações de filmes que o usuário não viu, utilizadas na validação da recomendação.

4.1.4.1 – Telas do sistema

Uma inovação acrescentada nesta etapa foi a possibilidade de conectar-se ao sistema via Facebook. A nova tela de autenticação apresenta uma terceira opção, onde é possível pressionar o botão “Connect”. O controle sobre a autenticação neste caso é delegado ao Facebook, que solicita ao usuário permissão para acesso a algumas informações, como endereço de e-mail, foto do perfil, etc..



Filmes em grupo

Olá participante!

Você é novo por aqui?

Não

Sim

Usar minha conta do Facebook


 Connect

Figura 20 – Boas vindas da terceira etapa do Filmes em Grupo



Instruções do sistema

Olá participante, seja bem-vindo ao sistema Filmes em Grupo, elaborado pelo aluno de mestrado Pedro Rougemont.

O intuito deste sistema é o de tão somente coletar informações de forma a aperfeiçoar a pesquisa na Área de Sistemas de Recomendação, presentes em muitos dos sistemas já usados por você, como as recomendações presentes no site Netflix®, ou no próprio Facebook®, com o qual este sistema se integra.

Para utilizar o sistema, basta que, para cada filme:

- Se já viu o filme: deixe sua nota de 1 a 5 estrelas, onde 1 é muito ruim, e 5 muito bom
- Se não viu o filme: deixe um parecer sobre o que espera dele. Expresse a opinião que mais se aproxime da sua a respeito do filme dentre os 3 botões disponíveis. Se precisar de mais informações, é possível clicar na imagem do filme, que o levará ao link do mesmo no site IMDB (Internet Movie Database).
- Se simplesmente quiser pular o filme: basta apertar no botão fechar, no topo à direita

Boa sorte e obrigado por sua ajuda!

Prosseguir

Figura 21 – Instruções da terceira etapa do Filmes em Grupo

A tela foi bastante simplificada, dispondo ao usuário somente quatro filmes por vez, lado a lado. A avaliação por estrelas foi mantida, no entanto agora com uma conotação diferente da anterior. O usuário realmente deve ter assistido o filme antes de avaliá-lo, o que é indicado pelo rótulo “Vi” à esquerda do componente. Para os casos em que o usuário não tenha assistido ao filme, três botões com os seguintes rótulos permitem que este expresse sua impressão a priori, com as possibilidades: “Não vi, mas até que veria”; “Não vi e não quero ver”; “Não vi e não sei dizer”. Interpretados respectivamente como aprovação, rejeição e indiferença caso recebessem os filmes como recomendação.

Explicite suas preferências

Retornar às instruções de uso.

Highlander 3 - O Feiticeiro...	Power Rangers - O Filme (199...	City Hall - Conspiração no A...	Kill Bill - Volume 1 (2003)
			
Vi <input type="radio"/> ★★★★★	Vi <input type="radio"/> ★★★★★	Vi <input type="radio"/> ★★★★★	Vi <input type="radio"/> ★★★★★
<input type="radio"/> Não Vi	<input type="radio"/> Não Vi	<input type="radio"/> Não Vi	<input type="radio"/> Não Vi
<input type="button" value="mas até que veria"/>	<input type="button" value="mas até que veria"/>	<input type="button" value="mas até que veria"/>	<input type="button" value="mas até que veria"/>
<input type="button" value="e não quero ver"/>	<input type="button" value="e não quero ver"/>	<input type="button" value="e não quero ver"/>	<input type="button" value="e não quero ver"/>
<input type="button" value="e não sei dizer"/>	<input type="button" value="e não sei dizer"/>	<input type="button" value="e não sei dizer"/>	<input type="button" value="e não sei dizer"/>

Figura 22 – Tela de explicitação de preferências da terceira etapa

Ainda é possível pressionar o botão de fechar localizado no canto superior direito de cada filme, que é contabilizado da mesma maneira que a expressão de indiferença sobre a recomendação.

4.1.4.2 – Balanço Geral

Até o momento, esta etapa se mostrou a mais promissora no que se refere a alcançar os objetivos para os quais foi projetada. A integração com o Facebook favoreceu a divulgação, e o número de usuários cadastrados no sistema após o início da terceira etapa já dobrou. Houve *feedback* positivo dos usuários que participaram também das etapas anteriores.

4.1.4.3 – Números da Etapa

O resultado até o momento é de noventa e seis novos usuários cadastrados, somado ao retorno de oito participantes de etapas anteriores. Os demais números poderão ser vistos a seguir.

Tabela 7 – Números da Etapa 3 do Filmes em Grupo

Índice	Valor
Total de usuários na base até o momento	144
Total de usuários cadastrados nesta etapa	96
Usuários que já acessaram o sistema na 3a etapa	104
Filmes pontuados com estrelas	1511
Filmes não vistos, que agradariam os usuários	926
Filmes não vistos, que desagradariam os usuários	894
Filmes não vistos, indiferentes aos usuários	935

Os dados colhidos nesta etapa foram utilizados para avaliar a metodologia proposta no Capítulo 3, junto a outras bases de dados.

Capítulo 5 – Experimentos

Após a coleta de uma quantidade suficiente de dados na terceira etapa do projeto “Filmes em Grupo”, optamos por trabalhar com os dados de uma maneira mais autônoma, eliminando a dependência da consulta aos usuários durante a validação da recomendação. Baseamos fortemente nossa metodologia naquela descrita em (BALTRUNAS *et al.*, 2010), que além de dispensar a consulta posterior a usuários, pode ser aplicada a bases de dados de recomendação individual em geral.

Em função desta última possibilidade, decidimos também validar nossa proposta contra conjuntos de dados da recomendação individual. Contudo, como veremos adiante, algumas considerações precisam ser pontuadas com relação a esta adaptação, como por exemplo, o impacto da esparsidade dos dados, inerente a este tipo de entrada.

5.1 – Conjuntos de dados considerados

Utilizamos três conjuntos de dados como entrada para os experimentos. O primeiro deles foi o conjunto gerado na terceira etapa do sistema Filmes em Grupo, descrito no Capítulo 4. Os demais conjuntos foram obtidos do grupo de pesquisa *GroupLens*, gerados durante o experimento de recomendação individual *Movielens*. As duas bases consideradas se originam da base de 100.000 avaliações, referida no texto como *Movielens 100K*.

Em relação à base *Movielens 100K*, utilizamos duas variações, sendo a primeira constituída pela base na íntegra. A outra foi formada por um corte sobre o conjunto de dados em que houvesse uma grande variância de avaliações sobre os itens. Para isso, selecionamos itens cuja variância fosse igual ou superior ao 75-percentil da base de dados, caracterizando um subconjunto de itens “polêmicos”. Dessa forma, os três conjuntos de dados utilizados como entrada no sistema foram:

- Filmes em Grupo
- *Movielens* 100K
- *Movielens* 100K - itens c/ alta variância

Para cada conjunto foi assumido que o sistema de recomendação não admite *Reprise*, pressuposto adotado por (BALTRUNAS *et al.*, 2010) e consonante também com o formato do de dados do sistema Filmes em Grupo. No intuito de simular a mesma separação nas demais bases, estas foram submetidas a uma divisão artificial entre treino e teste, obtida pela técnica de validação cruzada K-fold.

Uma vez que o problema de Recomendação em Grupo considera que a entrada seja uma matriz de preferências sem elementos nulos, um procedimento adicional foi adotado para preencher a matriz de treinamento. Optou-se por preencher suas avaliações através da aplicação de Filtro Colaborativo com redução de dimensionalidade. A técnica de redução de dimensionalidade utilizada para a previsão foi a *Improved Regularized SVD*, apresentada na seção 2.2.1.4.2.3 deste trabalho.

Outras variações referentes aos dados foram realizadas durante as iterações dos experimentos, como veremos no tópico 5.2, possibilitando a identificação de cenários em que cada estratégia de Recomendação em Grupo possa atuar com melhor desempenho.

5.2 – Formatação dos experimentos

Os experimentos foram conduzidos da mesma maneira para cada uma das bases consideradas. Algumas estratégias foram tomadas como base para comparação de resultados. As estratégias tradicionais escolhidas foram Média Simples, Miséria Mínima, Ditatorial, Multiplicativa e Aleatória. Estas foram comparadas à estratégia proposta, Usuário Mais Representativo, ou MRU, com uso das distâncias: euclidiana (MRU euclidiana), Manhattan (MRU Manhattan) e euclidiana sobre espaço de variáveis latentes (MRU euclidiana SVD).

- **Entrada**
 - $U = \{u_1, u_2, \dots, u_n\}$ – Conjunto de usuários
 - $I = \{i_1, i_2, \dots, i_m\}$ – Conjunto de itens
 - $R_{n \times m}$ – Matriz de preferências esparsa
- **Processamento**
 - Aplique particionamento K-Fold à matriz R
 - Para cada partição:
 - Tome a partição atual como P (treino) e o restante como Q (teste)
 - Preencha P utilizando Improved Regularized-SVD Collaborative Filtering
 - Divida a base de usuários em K grupos U_k de mesmo tamanho
 - Para cada U_k
 - Separe P_k e Q_k , contendo apenas preferências de $u \in U_k$
 - Para cada estratégia de agregação S_t , gere $L_t = S_t(U_k)$, a lista de itens recomendados por S_t para U_k
 - Gere a lista ideal L_1 a partir de Q_k para cada $u \in U_k$
 - Calcule o nDCG e o quociente de Kendall-tau para cada L_t relativo a L_1 , separadamente para cada $u \in U_k$

Algoritmo 4 - Pseudocódigo do experimento para validação da proposta

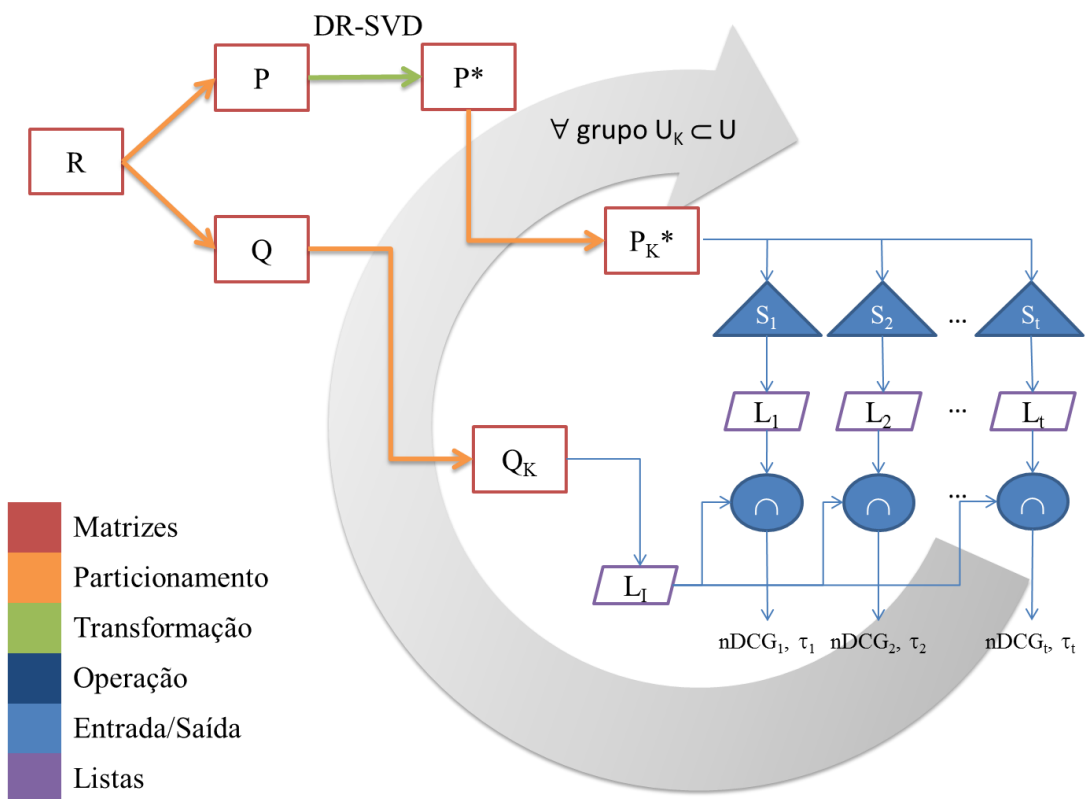


Figura 23 – Representação das iterações do experimento para validação da proposta

É importante pontuar as seguintes questões não ilustradas no pseudocódigo do experimento:

- Como indicado na imagem, para o grupo U_k foram validadas apenas avaliações que encontraram valor correspondente em Q_k . Em outras palavras, consideramos apenas avaliações de P_k^* previstas pelo filtro colaborativo, e não avaliações explicitadas por usuários, uma vez que P_k e Q_k são complementares. Esta restrição é sugerida em (BALTRUNAS *et al.*, 2010).
- A adaptação da base gerada pelo sistema Filmes em Grupo, para adequar-se ao formato das demais, considerou-se como P as avaliações emitidas por estrelas (faixa de 1 a 5) e construiu-se Q com pareceres do usuário u para o item i segundo a regra:
 - Não vi e não veria: $Q(u, i) = 1$;
 - Não vi e sou indiferente: $Q(u, i) = 3$;
 - Não vi e veria: $Q(u, i) = 5$.

Além disso, o algoritmo principal foi sujeito às seguintes variações:

- Variação no particionamento de R em P e Q de acordo com a base considerada, diretamente ligada a sua esparsidade. Para a base de 100K, a proporção adotada para treino e teste foi de 25:75. Para a base Filmes em Grupo, a divisão é imediata da própria base.
- Variação no critério de formação dos grupos. Cada experimento foi realizado diante de certo critério de formação de U_K . Estes se distinguiram da seguinte maneira:
 - Variação quanto à similaridade interna do grupo: formação aleatória, alta similaridade interna e baixa similaridade interna.
 - Variação no tamanho de U_K : quatro e oito usuários para todos os experimentos.

5.3 – Análise dos Resultados

Os resultados apresentados a seguir foram divididos por conjunto de dados e medida utilizada. Apresentamos duas tabelas para cada base, a primeira referente à medida nDCG e a segunda relativa ao coeficiente Tau de Kendall. Em cada tabela, as linhas apresentam um

cenário de formação dos grupos, para o qual as medidas foram tomadas. Foram calculadas a média μ e desvio σ amostrais, consolidados para todos os *folds* de um mesmo cenário.

Analisaremos inicialmente a medida nDCG. Para ambos os conjunto de dados, a faixa de valores de avaliações é entre 1 e 5, logo, o valor mínimo que esta medida pode apresentar é:

$$DCG_{min} = 1 + \sum_{i=2:10} 1 / \log_2(i) = 1 + \log_2^{-1}(362880) = \log_2^{-1}(725760)$$

$$DCG_{max} = 5 + \sum_{i=2:10} 5 / \log_2(i) = 1 + \log_2^{-1}(362880^5) = 5 * \log_2^{-1}(725760)$$

$$nDCG_{min} = \frac{DCG_{min}}{DCG_{max}} = 0,2$$

Como o fator normalizador é DCG_{max} , o valor máximo desta medida é 1. No entanto, seu valor esperado será proporcional à ocorrência de cada um dos valores de avaliação no conjunto de dados em questão, e deve ser discutido caso a caso.

Para a medida coeficiente Tau de Kendall, temos que seu valor mínimo é -1, na ocorrência de total discordância entre listas, e máximo 1, quando a lista resultante é exatamente a lista do usuário para o qual a medida foi calculada. Para um sorteio aleatório de duas listas, em que os fatores de concordância e discordância da Equação 4 possuem mesma probabilidade de ocorrer, devemos esperar o valor 0 para o coeficiente.

5.3.1 – Filmes em Grupo

Tabela 8 – Resultados da medida nDCG para o conjunto de dados Filmes em Grupo

	MRU SVD		MRU euclidiana		MRU Manhattan		Média Simples		Ditatorial		Miséria Mínima		Multiplicativa		Aleatória	
	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ
Alta similaridade - 4 usuários	0.76	0.16	0.75	0.17	0.75	0.16	0.81	0.10	0.73	0.17	0.76	0.16	0.81	0.11	0.66	0.20
Alta similaridade - 8 usuários	0.72	0.17	0.74	0.16	0.74	0.16	0.79	0.11	0.73	0.14	0.74	0.15	0.80	0.12	0.67	0.17
Baixa similaridade - 4 usuários	0.75	0.15	0.73	0.13	0.71	0.15	0.75	0.14	0.73	0.13	0.70	0.13	0.75	0.14	0.58	0.15
Baixa similaridade - 8 usuários	0.70	0.15	0.73	0.13	0.73	0.13	0.77	0.13	0.74	0.14	0.68	0.16	0.77	0.14	0.59	0.17
Formação aleatória - 4 usuários	0.70	0.14	0.76	0.14	0.72	0.14	0.78	0.10	0.75	0.12	0.71	0.10	0.78	0.10	0.60	0.15
Formação aleatória - 8 usuários	0.78	0.13	0.77	0.13	0.79	0.11	0.81	0.12	0.74	0.12	0.73	0.16	0.80	0.12	0.62	0.14

Tabela 9 – Resultados da medida coeficiente Tau de Kendall para o conjunto de dados Filmes em grupo

	MRU SVD		MRU euclidiana		MRU Manhattan		Média Simples		Ditatorial		Miséria Mínima		Multiplicativa		Aleatória	
	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ
Alta similaridade - 4 usuários	0.14	0.32	0.13	0.27	0.11	0.33	-0.06	0.28	0.10	0.29	0.21	0.32	-0.12	0.27	0.05	0.27
Alta similaridade - 8 usuários	0.10	0.28	0.09	0.37	0.09	0.37	-0.09	0.22	0.16	0.32	0.15	0.34	-0.06	0.24	0.05	0.20
Baixa similaridade - 4 usuários	0.06	0.35	0.06	0.25	0.10	0.24	0.06	0.28	0.12	0.24	0.13	0.27	-0.03	0.26	-0.04	0.21
Baixa similaridade - 8 usuários	0.14	0.28	0.02	0.29	0.02	0.29	-0.02	0.29	0.09	0.31	0.16	0.32	-0.03	0.25	-0.04	0.25
Formação aleatória - 4 usuários	0.11	0.33	-0.02	0.24	0.01	0.29	-0.14	0.22	0.16	0.44	0.01	0.26	-0.14	0.23	0.13	0.29
Formação aleatória - 8 usuários	0.07	0.37	0.08	0.35	0.02	0.39	-0.02	0.27	0.07	0.36	0.04	0.30	-0.05	0.25	0.08	0.22

Para o conjunto de dados Filmes em Grupo, observamos que a distribuição de notas no conjunto de testes é aproximadamente a mesma, como visto no balanço geral da terceira etapa, Tabela 7. Sendo assim, a mesma proporção entre notas 1, 3 e 5 é esperada na base, representando respectivamente as respostas “não veria”, “sou indiferente” e “veria”, cada qual com probabilidade 1/3. Imediatamente temos que o valor esperado de avaliações no conjunto de testes é 3, e o valor de nDCG esperado é de 0,6.

A Tabela 8 apresenta coerência com este primeiro resultado, uma vez que a média amostral da estratégia Aleatória, cujo comportamento tende ao valor esperado de cada medida, se encontra em torno de 0,6. Acentuamos em negrito os melhores resultados para a média amostral. Algumas considerações pertinentes:

- As estratégias Média Simples e Multiplicativa apresentam os melhores resultados para a medida;
- As três variantes de MRU testadas apresentaram aproximadamente mesmo desvio padrão em torno de $0,15 \pm 0,02$ para todos os cenários, e um bom valor de média;
- Houve pelo menos um cenário em que cada uma das três variantes de MRU apresentou melhor resultado que as outras variantes, não havendo indícios de que isso se deva a algum aspecto referente à similaridade interna ou tamanho dos grupos;

- A estratégia MRU euclidiana apresentou resultados melhores de média amostral que a estratégia Ditatorial e Miséria Mínima, para quase todos os cenários.

Nossa avaliação sobre os resultados apresentados na Tabela 9 para o coeficiente Tau de Kendall na Base Filmes em Grupo foi de que:

- Apesar de apresentar valores de variância aparentemente altos, a medida não passou por processo de normalização, o que levaria sua variância para metade dos valores apresentados.
- Nesta medida, as estratégias Miséria Mínima e Ditatorial obtiveram melhores resultados de média, alternando-se entre as melhores por cenário.
- As três variantes de MRU obtiveram resultados satisfatórios, com valores de média centrados em torno de 0 a 0,13.
- Novamente houve ao menos um cenário em que cada variante de MRU superou uma outra.
- A Média Simples e a estratégia Multiplicativa demonstraram resultados piores do que a estratégia proposta em todos os cenários analisados.

Tomando-se estas duas medidas sobre esta base, há um indicativo de que a estratégia MRU se apresenta como um meio termo entre estratégias que se propõem a maximizar a satisfação global, e aquelas que se propõem a minimizar o conflito de interesses de membros.

Ainda que não apresente os melhores valores em nenhum dos dois casos, seus valores foram satisfatórios. É preciso verificar se este resultado se mantém para as demais bases.

5.3.2 – *Movielens 100K*

Tabela 10 – Resultados da medida nDGC para o conjunto de dados *Movielens 100K*

	MRU SVD		MRU euclidiana		MRU Manhattan		Média Simples		Ditatorial		Miséria Mínima		Multiplicativa		Aleatória	
	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ
Alta similaridade - 4 usuários	0.88	0.05	0.86	0.06	0.86	0.06	0.87	0.06	0.87	0.06	0.88	0.06	0.87	0.06	0.75	0.09
Alta similaridade - 8 usuários	0.85	0.08	0.85	0.08	0.85	0.08	0.85	0.09	0.86	0.08	0.86	0.08	0.85	0.09	0.75	0.11
Baixa similaridade - 4 usuários	0.90	0.07	0.89	0.07	0.88	0.08	0.89	0.08	0.87	0.10	0.90	0.07	0.89	0.08	0.80	0.09
Baixa similaridade - 8 usuários	0.87	0.07	0.88	0.08	0.88	0.08	0.89	0.08	0.85	0.10	0.88	0.08	0.89	0.08	0.75	0.11
Formação aleatória - 4 usuários	0.86	0.08	0.87	0.08	0.87	0.08	0.87	0.10	0.87	0.08	0.87	0.09	0.88	0.09	0.74	0.11
Formação aleatória - 8 usuários	0.85	0.07	0.85	0.07	0.85	0.07	0.85	0.08	0.85	0.07	0.85	0.08	0.85	0.08	0.75	0.12

Tabela 11 – Resultados da medida coeficiente Tau de Kendall para o conjunto de dados *Movielens 100K*

	MRU SVD		MRU euclidiana		MRU Manhattan		Média Simples		Ditatorial		Miséria Mínima		Multiplicativa		Aleatória	
	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ
Alta similaridade - 4 usuários	0.16	0.23	0.13	0.29	0.13	0.29	0.13	0.28	0.19	0.23	0.11	0.24	0.13	0.28	0.09	0.30
Alta similaridade - 8 usuários	0.21	0.26	0.25	0.27	0.25	0.25	0.14	0.24	0.23	0.24	0.12	0.24	0.14	0.24	0.12	0.29
Baixa similaridade - 4 usuários	0.13	0.34	0.09	0.29	0.12	0.31	0.12	0.32	0.42	0.37	0.20	0.25	0.12	0.33	0.10	0.34
Baixa similaridade - 8 usuários	0.14	0.28	0.20	0.29	0.20	0.29	0.19	0.22	0.29	0.32	0.27	0.27	0.18	0.24	-0.05	0.22
Formação aleatória - 4 usuários	0.13	0.26	0.19	0.30	0.19	0.30	0.10	0.26	0.18	0.30	0.23	0.31	0.04	0.29	-0.02	0.27
Formação aleatória - 8 usuários	0.23	0.26	0.22	0.24	0.22	0.24	0.12	0.22	0.23	0.27	0.14	0.23	0.12	0.23	0.01	0.28

Aqui observamos que a esparsidade da matriz de avaliações *Movielens 100K* compromete a diversidade dos resultados que podemos extrair com a medida nDCG. O que a Tabela 10 parece nos mostrar é que o procedimento de Filtro Colaborativo, responsável pelo preenchimento dos valores desconhecidos, acaba por homogeneizar esta base, reduzindo bastante a diversidade entre resultados obtidos por estratégias diferentes.

É notório que os resultados das estratégias demonstram coerência e bom desempenho se comparadas uma a uma à estratégia Aleatória. Contudo, da mesma maneira, eles são praticamente indistinguíveis. As estratégias baseadas no Usuário Mais Representativo acabaram por desenvolver um desempenho melhor do que no experimento anterior, sendo a MRU SVD detentora de metade dos melhores resultados.

A medida Tau de Kendall aponta neste caso para a mesma tendência observada no anterior, em que as estratégias Ditatorial e Miséria Mínima se saem melhor. Novamente as variantes de MRU superam a Média Simples e a Multiplicativa para quase todos os casos, o que reforça a ocorrência geral deste padrão.

5.3.2 – Movielens 100K HV

Tabela 12 – Resultados da medida nDGC para o conjunto de dados Movielens 100K composta por itens c/ alta variância

	MRU SVD		MRU euclidiana		MRU Manhattan		Média Simples		Ditatorial		Miséria Mínima		Multiplicativa		Aleatória	
	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ
Alta similaridade - 4 usuários	0.86	0.11	0.87	0.10	0.87	0.10	0.87	0.09	0.88	0.09	0.87	0.10	0.87	0.09	0.83	0.06
Alta similaridade - 8 usuários	0.88	0.09	0.88	0.09	0.89	0.10	0.86	0.09	0.88	0.09	0.87	0.08	0.86	0.09	0.81	0.10
Baixa similaridade - 4 usuários	0.89	0.08	0.88	0.07	0.88	0.07	0.89	0.07	0.89	0.08	0.89	0.07	0.89	0.07	0.81	0.13
Baixa similaridade - 8 usuários	0.84	0.11	0.84	0.11	0.84	0.11	0.85	0.09	0.84	0.11	0.84	0.12	0.85	0.10	0.76	0.16
Formação aleatória - 4 usuários	0.81	0.13	0.81	0.13	0.80	0.16	0.79	0.13	0.77	0.17	0.76	0.16	0.78	0.14	0.73	0.16
Formação aleatória - 8 usuários	0.79	0.15	0.79	0.15	0.79	0.14	0.81	0.12	0.79	0.15	0.79	0.16	0.81	0.12	0.75	0.12

Tabela 13 – Resultados da medida coeficiente Tau de Kendall para o conjunto de dados Movielens 100K composta por itens c/ alta variância

	MRU SVD		MRU euclidiana		MRU Manhattan		Média Simples		Ditatorial		Miséria Mínima		Multiplicativa		Aleatória	
	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ
Alta similaridade - 4 usuários	0.22	0.23	0.22	0.23	0.22	0.09	0.18	0.21	0.13	0.20	0.24	0.09	0.18	-0.28	0.18	0.22
Alta similaridade - 8 usuários	0.19	0.20	0.20	0.20	0.24	0.02	0.24	0.14	0.26	0.20	0.25	0.03	0.15	0.01	0.20	0.19
Baixa similaridade - 4 usuários	0.28	0.22	0.15	0.27	0.26	0.23	0.32	0.29	0.27	0.32	0.15	0.23	0.31	0.05	0.23	0.28
Baixa similaridade - 8 usuários	0.28	0.21	0.23	0.21	0.23	0.09	0.25	0.18	0.24	0.22	0.20	0.07	0.31	0.11	0.23	0.28
Formação aleatória - 4 usuários	0.23	0.06	0.19	0.07	0.19	-0.02	0.25	0.03	0.17	0.12	0.19	0.07	0.15	0.01	0.32	0.23
Formação aleatória - 8 usuários	0.29	0.13	0.16	0.12	0.17	0.10	0.31	0.18	0.15	0.21	0.28	0.07	0.32	-0.03	0.27	0.29

O uso do conjunto de dados restrito a um pequeno subgrupo de itens com maior variância afetou o padrão de resultados de ambas as medidas. Na medida nDCG, a média amostral subiu para todas as estratégias, inclusive a estratégia Aleatória. Observamos o mesmo padrão de empates e valores próximos entre resultados de diferentes estratégias, em função dos problemas já observados no caso anterior.

Já os resultados da aplicação do coeficiente Tau de Kendall apresentam características muito mais interessantes para esta base:

- As estratégias Média Simples e Multiplicativa observaram significativa melhora e corresponderam à 2/3 dos valores máximos para média amostral
- O desvio padrão amostral reduziu vertiginosamente para algumas estratégias e cenários, como são os casos da Multiplicativa, Miséria Mínima, e MRU Manhattan (destacados também em negrito). Uma possível causa para isto seria o número reduzido de informações para teste neste corte sobre a base.
- MRU não supera desta vez, nenhuma das demais estratégias.

Capítulo 6 – Conclusões

6.1 – Considerações acerca do trabalho

Este trabalho apresentou uma nova proposta para o problema de Recomendação em Grupo, com foco apenas em uma das etapas de Sistemas de Recomendação para Grupos – a etapa de Agregação. A estratégia Usuário Mais Representativo (MRU) procura explorar informações latentes na matriz de preferências, com o objetivo de realizar uma recomendação mais concisa para o grupo.

Assume-se a existência de espaços métricos onde usuários e itens são representados. Tais espaços podem ser formados diretamente pelos vetores de preferências individuais ou por uma decomposição da matriz contendo tais preferências; sendo este último o método escolhido para a nossa proposta. Funções de distância são utilizadas para medir a distância entre os usuários, no espaço métrico dos mesmos, com o objetivo de encontrar o usuário que tenha a menor distância para todos os demais (usuário medóide). Desta forma, criamos um estereótipo para o grupo, que é o usuário mais representativo.

A recomendação do grupo passa então a ser a recomendação para seu usuário mais representativo. Esta abordagem demonstrou bons resultados quando comparada com as estratégias tradicionais da literatura. Além disso, foi demonstrado que a estratégia possui propriedades que lhe garantem robustez contra problemas comuns em sistemas que tratam de grupos, como a questão da manipulabilidade.

6.2 – Contribuições

Além de propor da estratégia MRU, este trabalho contribuiu com o desenvolvimento do sistema Filmes em Grupo, cuja finalidade atual é a de coletar dados direcionados para experimentos da área de Recomendação em Grupos. Nosso objetivo é manter o sistema ativo pelos próximos dois anos, incrementando seu conteúdo e funcionalidades.

O sistema rendeu o conjunto de dados utilizado em nossos experimentos, do qual obtivemos resultados que auxiliaram a mensurar a qualidade da estratégia proposta. Ele continua em atividade, no endereço http://recsys.cos.ufrj.br/filmes_em_grupo. Seu funcionamento se mantém conforme o descrito como a terceira etapa, no Capítulo 4.

Uma página na comunidade virtual *Facebook* foi criada para que voluntários e interessados acompanhem as atualizações do sistema, seu endereço é <https://www.facebook.com/FilmesEmGrupo>. Versões do conjunto de dados do sistema são disponibilizadas publicamente no endereço http://recsys.cos.ufrj.br/filmes_em_grupo/datasets.

6.3 – Limitações e trabalhos futuros

Vimos que em determinados cenários de SRG, onde não haja dinamicidade dos grupos e tampouco atualizações frequentes de avaliações, a estratégia MRU pode apresentar caráter ditatorial. Seria pertinente a realização de experimentos onde pudéssemos monitorar o momento em que a estratégia esteja assumindo esta propriedade. Logo, seria possível determinar com maior precisão condições que, se identificadas, poderiam orientar o SRG para a modificação da estratégia adotada.

Dentre as possíveis extensões ao trabalho desenvolvido nesta dissertação, uma delas seria testar funções de distância alternativas para a estratégia MRU além de outras transformações do espaço de usuários que não a redução por SVD.

Por outro lado, a base Filmes em Grupo também pode ser mais explorada em trabalho futuros. A condução dos experimentos neste trabalho foi propositalmente restrita ao artigo de (BALTRUNAS *et al.*, 2010). Por se tratar de uma base de dados nova, foi necessário antes validá-la com resultados obtidos em bases conhecidas na literatura.

Há a possibilidade de utilizar os dados do sistema Filmes em Grupo em outras configurações de experimentos para validar SRGs, que não seja a de Baltrunas. De preferência, uma configuração onde não seja necessário fazer nenhuma adaptação nos dados de teste.

A discussão promovida em 2.2.2.1 sobre a herança advinda da Teoria da Escolha Social e as adaptações de estratégias de Recomendação para Grupos para funções bem-estar social em 3.4 indicam um caminho para que mais estudos sejam desenvolvidos, relacionando contribuições de ambas as áreas.

Referências Bibliográficas

- AMER-YAHIA, S., ROY, S.B., CHAWLAT, A., et al., 2009, "Group recommendation: Semantics and efficiency". In: *Proceedings of the VLDB Endowment*. v. 2, n. 1, pp. 754–765.
- ANDERSON, C., HIRALALL, M., 2011, "Recommender systems for e-shops". In: pp. 34.
- ARROW, K.J., 1950, "A Difficulty in the Concept of Social Welfare". In: *Journal of Political Economy*. v. 58.
- ARROW, K.J., 1951. *Social Choice and Individual Values*. S.l.: Yale University.
- BALABANOVIĆ, M., SHOHAM, Y., 1997, "Fab: content-based, collaborative recommendation". In: *Communications of the ACM*. v. 40, n. 3, pp. 66–72.
- BALTRUNAS, L., MAKCINSKAS, T., RICCI, F., 2010. "Group recommendations with rank aggregation and collaborative filtering". In: *Proceedings of the fourth ACM conference on Recommender systems*. S.l.: s.n. 2010. pp. 119–126.
- BELLUCCI, E., ZELEZNIKOW, J., 1998. "A comparative study of negotiation decision support systems". In: *System Sciences, 1998., Proceedings of the Thirty-First Hawaii International Conference on*. S.l.: s.n. 1998. pp. 254–262.
- BERRY, M.W., BROWNE, M., 1999, *Understanding Search Engines: Mathematical Modeling and Text Retrieval*. S.l., SIAM.
- BOUYSSOU, D., DUBOIS, D., PIRLOT, M., et al., 2010, *Chapter 19. Social Choice Theory and Multicriteria Decision Aiding, in Decision-making Process: Concepts and Methods*. S.l., s.n. Acessado em: 10 Julho 2013.
- BREESE, J., HECKERMAN, D., KADIE, C., 1998. "Empirical Analysis of Predictive Algorithms for Collaborative Filtering.pdf". 1998. S.l.: s.n.
- BURKE, R., 2002, "Hybrid recommender systems: Survey and experiments". In: *User modeling and user-adapted interaction*. v. 12, n. 4, pp. 331–370.
- DE CAMPOS, L.M., FERNANDEZ-LUNA, J.M., HUETE, J.F., et al., 2007. "Group recommending: A methodological approach based on bayesian networks". In: *Data Engineering Workshop, 2007 IEEE 23rd International Conference on*. S.l.: s.n. 2007. pp. 835–844.
- CAMPOS, L.M., FERNÁNDEZ-LUNA, J.M., HUETE, J.F., et al., 2008, "Managing uncertainty in group recommending processes". In: *User Modeling and User-Adapted Interaction*. v. 19, pp. 207–242.

- CHEN, Y., 2011. "Interface and interaction design for group and social recommender systems". In: *Proceedings of the fifth ACM conference on Recommender systems*. S.l.: s.n. 2011. pp. 363–366.
- DEUTSCH, M., 1985, *Distributive Justice: A Social-Psychological Perspective*. S.l., Yale University Press.
- DUMAIS, S.T., 2004, "Latent semantic analysis". In: *Annual Review of Information Science and Technology*. v. 38, n. 1, pp. 188–230.
- ELSTER, J., HYLLAND, A., 1989, *Foundations of Social Choice Theory*. S.l., CUP Archive.
- FISHBURN, P.C., 1973, *The Theory of social choice*. S.l., Princeton University Press.
- FUNK, S., 2006. Disponível em: <<http://sifter.org/~simon/journal/20061211.html>>. Acessado em: 13 Agosto 2013.
- DE GEMMIS, M., IAQUINTA, L., LOPS, P., et al., 2009, "Preference learning in recommender systems". In: *PREFERENCE LEARNING*. v. 41.
- GIBBARD, A., 1973, "Manipulation of Voting Schemes: A General Result". In: *Econometrica*. v. 41, n. 4 (Jul.), pp. 587–601.
- GOLDBERG, D., NICHOLS, D., OKI, B.M., et al., 1992, "Using collaborative filtering to weave an information tapestry". In: *Communications of the ACM*. v. 35, n. 12, pp. 61–70.
- GREEN-ARMYTAGE, J., 2013, "Strategic Voting and Nomination". In: .
- HARSANYI, J.C., 1958, *A Bargaining Model for the Cooperative N-person Game*. S.l., Department of Economics, Stanford University.
- HERLOCKER, J., KONSTAN, J., BORCHERS, A., et al., 1999.
- HOCK, R., 2001, *The extreme searcher's guide to Web search engines: a handbook for the serious searcher*. Medford, NJ, CyberAge Books.
- JAMESON, A., 2004. "More than the sum of its members: challenges for group recommender systems". In: *Proceedings of the working conference on Advanced visual interfaces*. S.l.: s.n. 2004. pp. 48–54.
- JAMESON, A., SMYTH, B., 2007, "Recommendation to groups". In: *The adaptive web*. pp. 596–627.
- JÄRVELIN, K., KEKÄLÄINEN, J., 2002, "Cumulated gain-based evaluation of IR techniques". In: *ACM Transactions on Information Systems (TOIS)*. v. 20, n. 4, pp. 422–446.

- KANGAS, A., LAUKKANEN, S., KANGAS, J., 2006, "Social choice theory and its applications in sustainable forest management—a review". In: *Forest Policy and Economics*. v. 9, n. 1 (Nov.), pp. 77–92.
- KENDALL, M.G., 1938, "A new measure of rank correlation". In: *Biometrika*. v. 30, n. 1/2, pp. 81–93.
- MALONE, T.W., GRANT, K.R., TURBAK, F.A., et al., 1987, "Intelligent information-sharing systems". In: *Commun. ACM*. v. 30, n. 5 (May), pp. 390–402.
- MASTHOFF, J., 2002. "Modeling a group of television viewers". In: *Proceedings of the Workshop Future tv, in Intelligent Tutoring Systems Conference*. S.l.: s.n. 2002. pp. 34–42.
- MASTHOFF, J., 2004, "Group modeling: Selecting a sequence of television items to suit a group of viewers". In: *User Modeling and User-Adapted Interaction*. v. 14, n. 1, pp. 37–85.
- MASTHOFF, J., 2011. "Chapter 21. Group recommender systems: Combining individual models". In: *Recommender Systems Handbook*. S.l.: Springer. pp. 677–702.
- MCCARTHY, J.F., ANAGNOST, T.D., 1998, "MusicFX: An Arbiter of Group Preferences for Computer Supported Collaborative Workouts.pdf". In: .
- MCCARTHY, K., MCGINTY, L., SMYTH, B., et al., 2006a. "Social interaction in the cats group recommender". In: *Workshop on the social navigation and community based adaptation technologies*. S.l.: s.n. 2006.
- MCCARTHY, K., MCGINTY, L., SMYTH, B., et al., 2006b, "The needs of the many: A case-based group recommender system". In: *Advances in Case-Based Reasoning*. pp. 196–210.
- MITTAL, B., LASSAR, W.M., 1996, "The role of personalization in service encounters". In: *Journal of Retailing*. v. 72, n. 1, pp. 95–109.
- MOONEY, R.J., ROY, L., 2000. "Content-based book recommending using learning for text categorization". In: *Proceedings of the fifth ACM conference on Digital libraries*. S.l.: s.n. 2000. pp. 195–204.
- O'CONNOR, M., COSLEY, D., KONSTAN, J.A., et al., 2002. "PolyLens: A recommender system for groups of users". In: *ECSCW 2001*. S.l.: s.n. 2002. pp. 199–218.
- PATEREK, A., 2007. "Improving regularized singular value decomposition for collaborative filtering". In: *Proceedings of KDD cup and workshop*. S.l.: s.n. 2007. pp. 5–8.
- POPESCU, G., PU, P., 2010. *Group recommender systems as a voting problem*. S.l. EPFL Technical report.
- RICCI, F., CAVADA, D., MIRZADEH, N., et al., 2006, "Case-based travel recommendations". In: *Destination Recommendation Systems: Behavioural Foundations and Applications*. pp. 67–93.

- RICCI, F., ROKACH, L., SHAPIRA, B., et al., 2011, *Recommender Systems Handbook*. S.l., Springer.
- SATTERTHWAITE, M.A., 1975, "Strategy-proofness and Arrow's conditions: Existence and correspondence theorems for voting procedures and social welfare functions". In: *Journal of economic theory*. v. 10, n. 2, pp. 187–217.
- SCHAFER, J.B., KONSTAN, J., RIEDI, J., 1999. "Recommender systems in e-commerce". In: *Proceedings of the 1st ACM conference on Electronic commerce*. S.l.: s.n. 1999. pp. 158–166.
- SEN, A., 1970, "The Impossibility of a Paretian Liberal". In: *Journal of Political Economy*. v. 78, n. 1 (Jan.), pp. 152–157.
- SENOT, C., KOSTADINOV, D., BOUZID, M., et al., 2010. "Analysis of Strategies for Building Group Profiles". In: BRA, Paul De, KOBASA, Alfred & CHIN, David (eds.), *User Modeling, Adaptation, and Personalization*. S.l.: Springer Berlin Heidelberg. Lecture Notes in Computer Science, 6075. pp. 40–51.
- STRANG, G., 2006, *Linear Algebra and Its Applications*. S.l., Thomson, Brooks/Cole.
- SU, X., KHOSHGOFTAAR, T.M., 2009, "A Survey of Collaborative Filtering Techniques". In: *Advances in Artificial Intelligence*. v. 2009, pp. 1–19.
- WANG, X., SUN, L., WANG, Z., et al., 2012. "Group Recommendation Using External Follower for Social TV". In: *Multimedia and Expo (ICME), 2012 IEEE International Conference on*. S.l.: s.n. 2012. pp. 37–42.
- YI, M., DENG, W., 2009. "A Utility-Based Recommendation Approach for E-Commerce Websites Based on Bayesian Networks". In: S.l.: IEEE. Julho 2009. pp. 571–574.
- YILMAZ, E., ASLAM, J.A., ROBERTSON, S., 2008. "A new rank correlation coefficient for information retrieval". In: *Proceedings of the 31st annual international ACM SIGIR conference on Research and development in information retrieval*. S.l.: s.n. 2008. pp. 587–594.
- ZIPF, G.K., 1949, *Human behavior and the principle of least effort*. Oxford, England, Addison-Wesley Press.