

Sistemas de Recomendação para Grupos

Nuno Miranda, Teresa Gonçalves
d11797@uevora.pt, tcg@di.uevora.pt

Universidade de Évora
www.uevora.pt

Resumo O presente trabalho é um levantamento de conceitos e do estado da arte das principais abordagens e metodologias envolvidas no desenvolvimento de sistemas de recomendação individuais e para grupos. Este levantamento é um estudo prévio, de extrema importância, como ponto de partida para a realização de futuros trabalhos, com o objetivo de desenvolver novas abordagens na área de recomendação para grupos.

1 Introdução

Para colmatar o problema do excesso de informação foram desenvolvidas diversas técnicas e abordagens, tais como processamento de língua natural, extração de informação, classificação automática e sistemas de recomendação.

Nesta última abordagem dos sistemas de recomendação, para além de integrarem diversas das outras técnicas anteriormente referidas, tentam encontrar informação relevante de uma forma mais personalizada e enquadrada com os gostos, hábitos ou preferências do utilizador.

Estes sistemas de recomendação têm sido bastante explorados e utilizados em contextos de marketing, especialmente de e-marketing, tendo o intuito de promover novos produtos e serviços aos consumidores, com base nas suas preferências e hábitos, tentando dessa forma, maximizar o sucesso dos produtos recomendados ao invés de uma recomendação puramente aleatória.

Existem três abordagens principais nos mecanismos de recomendação; a chamada recomendação colaborativa, recomendações baseadas no conteúdo e finalmente, abordagens híbridas. A maior parte dos trabalhos e estudos desenvolvidos nesta área, partem do pressuposto que quem recebe a recomendação do sistema é um utilizador único, no entanto, existe ainda a problemática associada as recomendações feitas a grupos de utilizadores onde tem havido menos desenvolvimentos.

2 Sistemas de Recomendação

Os sistemas de recomendação são técnicas e ferramentas de software que permitem dar sugestões sobre a escolha de um, ou vários itens, ao utilizador [16,55]. As áreas onde estes sistemas são mais utilizados são na recomendação de compras, músicas, filmes, destinos de férias, notícias e livros.

Os sistemas de recomendação, especialmente aplicados no contexto web e das novas tecnologias, permitiram a resolução do problema conhecido como *fenómeno de cauda longa*¹ [68,17]. Esse termo é utilizado quando temos uma distribuição de dados muito desequilibrada e descendente, sendo um fenômeno que ocorre em lojas físicas ou em jornais com um espaço limitado para as notícias a apresentar.

O exemplo apresentado na Figura 1 ilustra uma distribuição nesses cenários, onde o eixo vertical representa a popularidade dos itens (número de vezes que são escolhidos), estando no eixo horizontal os itens ordenados de acordo com a sua popularidade. O que acontece é que apenas itens mais populares são expostos devido às limitações físicas de espaço. No gráfico, esses itens estariam do lado esquerdo do traço, na curva de distribuição; todos os outros itens, do lado direito do traço são negligenciados não sendo expostos fisicamente. Nestes contextos e com limitações de espaço dá-se prioridade aos itens populares, criando assim um ciclo vicioso em que os itens de nicho, ficam sempre relegados para segundo plano sem serem exibidos ou promovidos.




Figura 1. Distribuição de cauda longa

A aplicação dos mecanismos de recomendação em contextos web veio alterar esse comportamento, pois os itens exibidos não estão restringidos aos mais populares. Graças aos sistemas de recomendação, é possível apresentar aos utilizadores itens pouco populares, mas que ainda assim, preenchem as preferências de certos utilizadores.

A designação de item ou itens é normalmente utilizada para designar o que vai ser recomendado pelo sistema, assim como o conjunto de onde será extraída essa recomendação [55]. O termo de utilizador é por norma atribuído à pessoa que vai usufruir da recomendação do sistema [55]. No entanto não são apenas os itens que são analisados pelos sistemas de recomendação. Dependendo do sistema e da abordagem seguida, o próprio utilizador também pode ser analisado durante esse processo [24,16,9]. As transações, são o termo frequentemente utilizado para designar as interações entre o utilizador e o sistema de recomendação. Interações essas, que fundamentalmente são a obtenção de dados que permitem aos algoritmos efetuar futuras recomendações [60].

Os dados referentes às preferências do utilizador podem ser obtidos de forma explícita ou implícita [35,42]. Na forma explícita, o utilizador é questionado

¹ Do Inglês 'Long Tail Phenomenon'

sobre as suas preferências e gostos através de formulários ou questionários; em plataformas Web, esses questionários são normalmente apresentados logo na fase inicial, quando o utilizador pretende registar-se na plataforma garantindo que existem dados sobre todos os utilizadores presentes na plataforma.

Já na forma implícita a coleta desses dados é mais discreta e, por norma, o utilizador nem tem perceção que estão a ser recolhidos dados sobre as suas preferências e hábitos [42]. Nesta aproximação, são recolhidos dados sobre as páginas web que foram visitadas e o número de vezes que o foram; considera-se se essas páginas foram ou não adicionadas aos favoritos do browser; pode ser analisada a duração que o utilizador esteve em cada página, assim como se efetuou movimentos no scroll, mostrando que se interessou pelos conteúdos, demorando tempo a ler e a percorrer toda a página web; é ainda possível registar a data, hora, país de onde é efetuado o acesso, assim como a plataforma e sistema operativo de onde é efetuada a consulta [4].

A formalização do problema inerente aos mecanismos e sistemas de recomendação [2] passa por ter o utilizador c pertencente ao conjunto de utilizadores C e o item s pertencente ao conjunto de itens S com N elementos. Assim a função $U(c, s)$ é a responsável por obter a utilidade de uma recomendação. Para determinar o item ou itens com maior utilidade para um utilizador, é necessário aplicar essa função a todos os itens $U(c, s_1), \dots, U(c, s_N)$. Após essa operação, podem-se obter os itens ordenados pela sua utilidade s_{j_1}, \dots, s_{j_N} , ou apenas os K elementos mais relevantes s_{j_1}, \dots, s_{j_k} com $(K \leq N)$, ou ainda, apenas o item com maior utilidade, $s_j = \operatorname{argmax}_{j \in S} U(c, j)$.

Para alcançar os itens com utilidade máxima existe um grande número de técnicas e de abordagens que são agrupadas em famílias por terem uma aproximação semelhante. Algumas utilizam técnicas de aprendizagem automática, teorias de aproximação e diversas heurísticas.

A função de utilidade nem sempre é obtida objetivamente para todos os itens, pois nem todos eles não foram avaliados ou caracterizados de acordo com as preferências do utilizador. É sobretudo nesses itens não caracterizados que os sistemas de recomendação assumem uma importância elevada. Nesses casos a função de utilidade têm de ser estimada.

2.1 Abordagens de Filtragem de Conteúdos

Com esta abordagem, o sistema de recomendação gera os seus resultados de estimativa de utilidade, baseando-se nas características e atributos de outros itens que foram escolhidos ou preferidos pelo utilizador no passado. Ou seja, a obtenção da função de utilidade $U(c, s)$ para o utilizador c e para o item s é obtida através das utilidades dos outros itens para o mesmo utilizador $U(c, s_j)$, desde que os itens sejam todos semelhantes e com atributos comuns que permitam a comparação entre eles.

A aproximação baseada em conteúdos tem as suas origens em sistemas de extração de informação [6,58] e em sistemas de filtragem de informação [26]. Ambas as técnicas são bastante utilizadas porque muitos dos sistemas de reco-

mendação, trabalham sobre itens com informação descritiva em língua natural, como é o caso da recomendação de páginas web, de notícias e de livros.

No entanto, os melhores sistemas de recomendação baseados em conteúdos não se ficam pelas técnicas de extração e de filtragem de informação. Frequentemente adicionam técnicas de criação de perfis. Essas abordagens obtêm dados para além do item em si, recolhendo informação sobre as preferências do utilizador. Esses dados extra, como já foi introduzido anteriormente, podem ser obtidos de forma implícita [42,4] ou explícita [35,42].

Nos sistemas que assentam em itens baseados em textos em língua natural, recorre-se muitas vezes à computação e extração de palavras-chave. As palavras-chave obtidas dos diversos textos acabam por ser os atributos de comparação para a descoberta de itens que se enquadrem nos gostos do utilizador. Por exemplo o Sistema Fab [7] recomenda páginas Web ao utilizador tendo em conta as 100 palavras-chave mais importantes. De forma semelhante, o sistema Syskill & Webert [49] baseia as suas recomendações de páginas Web nas 128 palavras mais informativas. Para obter os termos mais significativos, existem várias aproximações, no entanto uma das mais utilizadas é o TFIDF² [26], que tem em conta a ocorrência do termo no documento em análise e no conjunto de todos os documentos de comparação do sistema de recomendação. Nesta técnica, um termo tem mais importância quanto mais se repete no documento, mas por sua vez, esse termo perde importância quantas mais vezes se repetir na coleção dos documentos.

No enriquecimento dos perfis dos utilizadores, também pode ser adicionada informação sobre palavras-chave e valores numéricos sobre elas, como por exemplo, o TFIDF, referido anteriormente. Com esses dados é possível criar um vetor de pesos (w_{c1}, \dots, w_{ck}) em que cada w_{ci} indica a importância de cada palavra-chave k_i para o utilizador c . Com esse vetor, é então possível aplicar um elevado número de técnicas para o cálculo e descoberta do itens de maior utilidade.

Existem abordagens que utilizam esse vetor e aplicam o algoritmo de Rocchio [57] que, de uma forma muito simplista tenta construir uma média representativa do utilizador. Tanto no trabalho de Fab [7] como no de NemsWeeder [31] é utilizada essa técnica. No entanto podem ser utilizadas outras abordagens como classificadores Bayesianos [49,45] para estimar a probabilidade de um item ser ou não interessante para o utilizador. Outros sistemas utilizam o algoritmo Winnow [34] que obtêm bons resultados quando aplicado nestas tarefas, especialmente quando existem muitos atributos no vetor de atributos [49]. Ainda podem ser utilizadas outras abordagens de aprendizagem automática, clusterização, árvores de decisão, redes neuronais e SVM's.

2.2 Abordagens Colaborativas

Nos sistemas de recomendação baseados em abordagens colaborativas, a estimativa de utilidade sobre os diversos itens é efetuada a partir da análise das escolhas de outros utilizadores com perfil semelhante.

² Sigla proveniente do Inglês, *Term Frequency-Inverse Document Frequency*

Uma das vantagens destas abordagens é permitir ter uma elevada, ou total, abstração sobre os itens e os seus atributos. Em situações onde os sistemas de recomendação baseados em conteúdos falham porque os itens têm poucos atributos ou esses atributos não são computáveis, esta limitação é completamente ultrapassada com os princípios das abordagens colaborativas [24,60]. Esta abordagem é uma das mais largamente utilizada na maioria das plataformas web que utilizam sistemas de recomendação com milhares ou milhões de itens e utilizadores, sendo até designada por correlação pessoa-pessoa [61].

Na construção de sistemas de recomendação deste tipo, e à semelhança dos sistemas de filtragem de conteúdos, também são criados vetores de atributos com pesos distintos para cada um deles, sendo posteriormente aplicadas diversas técnicas para correlacionar esses vetores. No entanto, neste caso, os atributos e respetivos valores são obtidos a partir de características dos utilizadores. A recolha dos atributos podem seguir uma aproximação explícita ou implícita (também à semelhança dos sistemas de filtragem de conteúdos).

Formalmente, esta abordagem baseia a sua recomendação na função utilidade para cada utilizador c e respetivo item s , sendo que a utilidade $U(c, s)$ é estimada através das utilidades $U(c_j, s)$, associadas ao item $s \in S$ e utilizadores $c_j \in C$ com características semelhantes a c .

O sistema Grundy [56] para a recomendação de livros, um dos primeiros a implementar esta abordagem, utilizava a designação de estereótipos para a aglutinação dos diferentes utilizadores em perfis, consoante as suas preferências. No entanto, a criação desses perfis era um processo inteiramente manual. Mais tarde, o sistema Tapestry [24], solicitava aos utilizadores que, manualmente, seleccionassem outros utilizadores com gostos semelhantes, baseando-se no seu histórico de itens. Os sistemas GroupLens [29,54], Video Recommender [27] e Ringo [63] foram os primeiros a efetuar este tipo de operações automaticamente e a obter a respetiva recomendação automática. Mais tarde, surgiu uma nova geração de sistemas mais complexos e eficientes como o algoritmo de recomendação de livros da Amazon [33], o sistema PHOAKS [66] para a recomendação de informação relevante na Web e o sistema Jester [25] para a recomendação de anedotas online.

Os sistemas de recomendação colaborativos podem, segundo [14], ser agrupados em duas sub-classes tendo em consideração o seu funcionamento. A primeira classe, é baseada em memória ou heurísticas³; a segunda classe de algoritmos colaborativos é baseada em modelos⁴. Ambas as abordagens serão analisadas, de seguida, em maior profundidade.

Algoritmos baseados em memória/heurísticas Estes algoritmos [14,21,46], efetuam as suas recomendações com base em heurísticas sobre todos os itens já classificados pelos utilizadores. Dessa forma, o valor estimado de recomendação para o utilizador c e o item s é obtido através de $r_{c,s}$ e não é mais que uma agregação das classificações atribuídas por outros utilizadores; não todos, mas

³ Do Inglês: *memory-based* ou *heuristic-based*

⁴ Do Inglês: *model-based*

os N utilizadores que tenham avaliado o item s mais semelhantes ao utilizador a quem se pretende efetuar a recomendação. Assim, a função r pode ser definida:

$$r_{c,s} = \text{aggr}r_{c',s} \quad \text{com} \quad c' \in \hat{C}$$

onde \hat{C} é o sub-conjunto dos N utilizadores mais semelhantes a c que avaliaram s ; já N pode variar entre um utilizador e todos os utilizadores do sistema.

A agregação pode ser feita de diversas formas tomar diversas, sendo uma das mais simples dada por

$$r_{c,s} = \frac{1}{N} \sum_{c' \in \hat{C}} r_{c',s}$$

que essencialmente é a simples média do valor de recomendação dos utilizadores semelhantes. Para além desta, podem ser utilizadas outras abordagens mais complexas como as presentes nos trabalhos [21,46,54,63].

Algoritmos baseados em modelos Os algoritmos colaborativos baseados em modelos [10,11,14,23,25], utilizam uma coleção de classificações de outros utilizadores para criar um modelo. Com base nesse modelo são, posteriormente, estimadas as recomendações para o utilizador em causa.

O funcionamento lato desta abordagem é essencialmente o mesmo ao utilizado nas técnicas de aprendizagem automática supervisionada onde, numa primeira fase é efetuada a aprendizagem do modelo com exemplos e numa segunda fase esse modelo é utilizado para efetuar classificações ou previsões [43,44]. Assim sendo, a maioria dos algoritmos de aprendizagem automática podem ser utilizados nesta abordagem tais como análise Bayesiana, árvores de decisão, SVM's, redes neuronais, entre outros. Com esta proximidade, [10] propõe um sistema de recomendação colaborativo baseado numa *framework* de aprendizagem automática juntamente com mecanismos de recolha de atributos dos utilizadores; neste sistema, e devido à *framework*, poderiam ser aplicados facilmente diversos algoritmos de aprendizagem e obter conclusões de resultados da sua adaptabilidade a este tipo de tarefas.

No entanto, o processamento e obtenção de recomendações a partir destes modelos não fica restrito a algoritmos utilizados na aprendizagem automática; os modelos também podem ser processados recorrendo ao algoritmo de *k-means clustering*[67], *Gibbs sampling* [67], modelo Bayesiano [19], modelo probabilístico relacional[23], regressão linear [59], modelo de máxima entropia [48] e até processos de decisão de Markov [62].

2.3 Outras abordagens

Para além das abordagens mais comuns descritas anteriormente, existem outras aproximações que, sendo menos relevantes nos problemas de recomendação, acabam por ser bastante úteis quando utilizadas em conjunto com as técnicas

principais (recomendação por filtragem de conteúdo e recomendação colaborativa). Da junção dessas técnicas, obtêm-se sistemas híbridos capazes de resolver algumas das limitações das abordagens principais [15].

A abordagem Demográfica [56] pode ser vista como um sub-tipo das técnicas colaborativas que baseiam a recomendação nos utilizadores semelhantes ao utilizador a que se pretende efetuar a recomendação. A grande diferença é que este não se baseia nos gostos e preferências dos outros utilizadores, mas sim em características pessoais dos utilizadores, como por exemplo, a idade, o estado civil, raça, género, habilitações literárias, trabalho, o país, região e cidade [50]. Embora esta abordagem só por si seja fraca e gere recomendações muito vagas e generalistas é uma técnica que, num sistema híbrido em associação com um sistema colaborativo, pode ajudar a resolver os problemas dos novos utilizadores e da fraca densidade de dados para utilizadores com gostos atípicos; nestes casos em que a recomendação não pode ser baseada na abordagem colaborativa, aplica-se a abordagem demográfica que, mesmo sendo mais genérica, consegue dar recomendações nesses casos específicos [50].

Outra abordagem que acaba por ser uma variação dos sistemas de filtragem de conteúdo é a filtragem baseada no contexto [1]. Esta concentra a sua análise nos atributos de contextualização e meta-informação sobre o item, ao invés de se focar nos seus atributos concretos. Um exemplo pode ser dado no contexto das notícias onde o sistema de recomendação, em vez de se focar na análise do conteúdo da notícia, baseia-se em quem escreveu a notícia, qual a categoria, a data de publicação ou até a organização que a publicou. Da mesma forma que um sistema híbrido com abordagem demográfica e a colaborativa permitia resolver alguns problemas da abordagem colaborativa, a filtragem de contexto num sistema híbrido com a filtragem de conteúdo permite resolver alguns problemas, nomeadamente o problema da entrada de um novo item no sistema.

3 Sistemas de Recomendação para Grupos

Tradicionalmente os sistemas de recomendação efetuam as suas recomendações para utilizadores individuais. No entanto, em alguns cenários e contextos a recomendação para um grupo de indivíduos é mais adequada. Atualmente não existe uma grande quantidade de trabalhos científicos baseados nos sistemas de recomendação para grupos e o número de aplicações online com esse fim é muito menor do que os trabalhos para recomendação individual. Um dos grandes desafios desses sistemas é lidar adequadamente com as preferências de cada elemento do grupo para gerar uma boa recomendação global [37].

Em alguns cenários do dia-a-dia a recomendação para utilizadores individuais não faz sentido, como por exemplo a escolha de um almoço de grupo [41,51], uma saída ao cinema por um grupo de amigos [47,36,69], umas férias em família onde é necessário escolher a cidade, o hotel e as atrações turísticas a visitar [28,41,22] ou a música para um evento com pessoas com diversos gostos [38,20,65,53].

É importante definir a noção de grupo. Um grupo é um conjunto de duas ou mais pessoas reunidas por alguma característica seja um interesse comum,

proximidade social, parentesco ou a partilha de um espaço físico. Segundo [13,12] existem quatro tipos de grupos:

- Grupo ocasional. Conjunto de pessoas que ocasionalmente realizam algo em conjunto e os seus membros têm um objetivo comum num determinado momento.
- Grupo estabelecido. Conjunto de pessoas que explicitamente escolheram fazer parte do grupo devido a um interesse de longo prazo compartilhado entre todos.
- Grupo aleatório. Conjunto de pessoas que partilham o mesmo ambiente num determinado momento, sem interesse explícito que as una umas às outras.
- Grupo identificado automaticamente. Conjunto de pessoas que é detetado de uma forma automática de acordo com as preferências ou hábitos dessas pessoas, não implicando proximidade física ou social.

Qualquer uma das definições de grupo anteriormente referidas, podem ainda ser classificadas como grupos homogéneos ou heterogéneos de acordo com a variância das preferências dos diversos elementos.

Alguns sistemas de recomendação para grupos encontrados são:

- MusicFX [38]. Este sistema permite seleccionar canais de música para serem tocados em ginásio. Os utilizadores manifestam as suas preferências quando se inscrevem e o sistema escolhe as músicas a serem tocadas de acordo com os utilizadores presentes no ginásio num determinado momento.
- Let's Browse [32]. Este sistema recomenda páginas web para grupos de dois ou mais elementos que queiram visualizar páginas web em conjunto.
- PolyLens [47]. Este sistema é uma especialização do já existente sistema MovieLens para a recomendação individual de filmes. O PolyLens [47] tem esse sistema como base e permite efetuar recomendações para grupos.
- Intrigue [5]. Este sistema recomenda atrações turísticas e pontos de interesse tendo em conta a possibilidade de existirem subgrupos, como por exemplo crianças. Também o sistema Travel Decision Forum [28] e o sistema CATS [40] são orientados à recomendação de férias e destinos turísticos para pessoas que o pretendam fazer em conjunto.

Destacam-se ainda mais alguns sistemas, como o GroupCast [39] dedicado a notícias, o GroupMender [30] e o Pocket Restaurant Finder [52] para a recomendação de restaurantes a grupos e o sistema AdaptiveRadio [18] para a selecção de rádios (semelhante ao MusicFx). No sistema YO's Recommender [69] é efetuada a recomendação de programas de televisão.

Independentemente da abordagem escolhida para implementar um sistema de recomendação para grupos, existem alguns critérios que devem ser tidos em conta e que podem ser utilizados como métricas de ajuste e de orientação dos próprios sistemas. Esses critérios são:

- **Maximizar a satisfação.** Este é um dos principais critérios e tenta maximizar a satisfação geral de todos os membros do grupo na escolha dos itens recomendados.

- **Minimizar o desagrado.** Na forma mais simples, este critério acaba por ser simplesmente o complementar do anterior. No entanto, há sistemas que dão maior importância à minimização de desagrado do que à maximização da satisfação como num cenário onde a maximização da satisfação implica a recomendação de um item altamente indesejado para um único elemento do grupo e o sistema opta por não maximizar essa variável mas efetuar uma maximização de satisfação mais suave para manter uma boa satisfação sem recomendar itens adversos a certos elementos do grupo.
- **Justiça.** Este critério, também designado por critério compensatório, está, em parte, associado ao critério anterior; no entanto, um elemento do grupo em vez de ser confrontado com um item indesejado é confrontado com um item sem grande interesse. Nestes casos, os outros itens recomendados devem tentar compensar esse elemento do grupo que foi penalizado, para haver alguma democratização nas recomendações efetuadas.
- **Manipulação.** Este critério é um pouco subjetivo e de difícil parametrização ou medição pois não está dependente do sistema de recomendação para grupos mas sim da sinceridade dos vários elementos do grupo. Ele ocorre quando um ou mais utilizadores do grupo tentam manipular o sistema no sentido de forçar uma recomendação. Este problema ocorre especialmente em sistemas com recolha dos dados e preferências de forma explícita.
- **Diferenciação de sub-grupos.** Este critério pode fazer sentido em alguns sistemas de recomendação, dependendo do contexto. Dentro de um grupo de utilizadores pode haver um sub-grupo com características diferenciadoras e implicar que esses elementos minoritários tenham mais peso/prioridade que os restantes elementos no mecanismo de recomendação. Um exemplo desse sub-grupo é, por exemplo, a existência de crianças, idosos ou pessoas com limitações.

Segundo [37] os sistemas de recomendação para grupos podem ser classificados de acordo com um conjunto de características binárias:

- O grupo tem um papel **ativo ou passivo** consoante pode ou não negociar as recomendações obtidas. A maioria dos sistemas remete o grupo para o papel passivo; no entanto, nos sistemas Travel Decision Forum [28] e CATS [40] a recomendação é negociada iterativamente com o grupo antes de ser apresentado o resultado final.
- O sistema recomenda um **único item ou uma lista ordenada** de acordo com o contexto onde vai ser aplicado.
- Preferências **pré-conhecidas ou desenvolvidas.** Na maioria dos sistemas as preferências dos utilizadores são conhecidas quando é executado o algoritmo de recomendação, mas o sistema CATS [40] inicia com recomendações muito genéricas e sem qualquer grau de personalização e, após vários passos de sugestão seguida da avaliação do utilizador, a recomendação começa a aproximar-se das preferências do utilizador.
- O sistema **identifica ou disponibiliza** os próprios itens. A maioria dos sistemas faculta uma recomendação ou listagem, como no sistema PolyLens

[47]. No entanto, alguns sistemas, como o MusicFX [42], devolvem diretamente o item recomendado, (neste caso concreto uma música que pode ser imediatamente tocada).

Uma das premissas dos sistemas de recomendação para grupos é que necessitam considerar as preferências individuais de cada membro do grupo para realizar a recomendação. Esta questão tornam estes sistemas mais difíceis e complexos que os sistemas tradicionais de recomendação. Os membros do grupo podem ter preferências e gostos diferentes, ou até, entrar em conflito e tal informação não pode ser desprezada e terá de ser envolvida no processo de recomendação.

Nos sistemas de recomendação para grupos, a obtenção de dados para alimentar o algoritmo segue essencialmente as mesmas abordagens dos sistemas individuais: podem seguir numa abordagem mais implícita, explícita, baseada em filtragem de conteúdos, de contexto, colaborativa ou demográfica. Neste ponto acaba por não haver uma grande distinção de sistemas de recomendação individual ou de grupos.

Na obtenção da recomendação propriamente dita, os sistemas orientados a grupos, tentam envolver de alguma forma a agregação e extrapolação das preferências individuais dos vários elementos para a noção de preferência do grupo. Existem três abordagens principais:

- **Agregação de recomendações individuais.** É a forma mais simplista de resolver este problema. Passa por ter uma agregação à posteriori do algoritmo de recomendação: é realizada uma recomendação individual para cada elemento do grupo, sendo posteriormente utilizada uma transformação linear para uniformizar as diversas recomendações para gerar a recomendação final. Esta abordagem é pouco utilizada por ser bastante simplista e pode ser analisada em maior detalhe em [3,8].
- **Agregação das preferências individuais.** Esta abordagem utiliza mecanismos mais complexos que a abordagem anterior. Aqui, efetua-se a agregação à priori: estes sistemas tentam criar um pseudo super-utilizador com as preferências de todos os elementos do grupo e aplicar então o algoritmo de recomendação. Esta abordagem tem sido bastante utilizada e desenvolvida. Alguns dos sistemas que utilizam esta abordagem temos o Intrigue [5], PolyLens [47], MusicFX [38] e o Pocket Restaurant Finder [52].
- **Construção de modelo de preferências.** esta abordagem utiliza todos os dados possíveis sobre as preferências e gostos dos utilizadores envolvidos e com isso cria um modelo representativo. Posteriormente, esse modelo é empregue na análise dos itens a serem recomendados e consequentemente selecionados. Esta abordagem para grupos é a mais próxima dos mecanismos de aprendizagem automática em que, fazendo um paralelismo, a aprendizagem do modelo corresponde à utilização das preferências dos utilizadores e a classificação equivale à recomendação final para o grupo. Alguns dos sistemas que utilizam esta abordagem são o Let's Browser [32], IN-VEHICLE Multimedia [70], YU's Recommender[69], I-SPY's [64], Travel Decision Forum [28] e GroupCast [39].

4 Conclusão

Como conclusão deste levantamento de conceitos e do estado da arte das abordagens e metodologias dos sistemas de recomendação. Pode-se concluir que foram aprofundados conhecimentos nessa área e assim solidificadas as bases de partida para o desenvolvimento de novas abordagens, especialmente na recomendação para grupos. Durante este estudo é notório que tem havido mais desenvolvimentos nos sistemas de recomendação individuais, no entanto sendo o interesse os sistemas destinados a grupos, os sistemas individuais não podem ser desprezados, pois as bases e técnicas de funcionamento são comuns. Como trabalho futuro pretende-se criar novas abordagens experimentais na área da recomendação para grupos e efetuar comparações com as abordagens já existentes.

Referências

1. Abowd, G.D., Dey, A.K., Brown, P.J., Davies, N., Smith, M., Steggle, P.: Towards a better understanding of context and context-awareness. In: Proceedings of the 1st International Symposium on Handheld and Ubiquitous Computing. pp. 304–307. HUC '99, Springer-Verlag, London, UK, UK (1999), <http://dl.acm.org/citation.cfm?id=647985.743843>
2. Adomavicius, G., Tuzhilin, A.: Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. *IEEE Trans. on Knowl. and Data Eng.* 17(6), 734–749 (Jun 2005), <http://dx.doi.org/10.1109/TKDE.2005.99>
3. Amer-Yahia, S., Roy, S.B., Chawlat, A., Das, G., Yu, C.: Group recommendation: Semantics and efficiency. *Proc. VLDB Endow.* 2(1), 754–765 (Aug 2009), <http://dx.doi.org/10.14778/1687627.1687713>
4. Anand, S.S., Mobasher, B.: Intelligent techniques for web personalization. In: Proceedings of the 2003 International Conference on Intelligent Techniques for Web Personalization. pp. 1–36. ITWP'03, Springer-Verlag, Berlin, Heidelberg (2005), http://dx.doi.org/10.1007/11577935_1
5. Ardissono, L., Goy, A., Petrone, G., Segnan, M., Torasso, P.: Intrigue: Personalized recommendation of tourist attractions for desktop and handset devices. In: Applied Artificial Intelligence. pp. 687–714. Taylor and Francis (2003)
6. Baeza-Yates, R.A., Ribeiro-Neto, B.: Modern Information Retrieval. Addison-Wesley Longman Publishing Co., Inc., Boston, MA, USA (1999)
7. Balabanović, M., Shoham, Y.: Fab: Content-based, collaborative recommendation. *Commun. ACM* 40(3), 66–72 (Mar 1997), <http://doi.acm.org/10.1145/245108.245124>
8. Baltrunas, L., Makcinskas, T., Ricci, F.: Group recommendations with rank aggregation and collaborative filtering. In: Proceedings of the Fourth ACM Conference on Recommender Systems. pp. 119–126. RecSys '10, ACM, New York, NY, USA (2010), <http://doi.acm.org/10.1145/1864708.1864733>
9. Basilico, J., Hofmann, T.: Unifying collaborative and content-based filtering. In: In ICML. pp. 65–72. ACM Press (2004)
10. Billsus, D., Pazzani, M.J.: Learning collaborative information filters. In: Proceedings of the Fifteenth International Conference on Machine Learning. pp. 46–54. ICML '98, Morgan Kaufmann Publishers Inc., San Francisco, CA, USA (1998), <http://dl.acm.org/citation.cfm?id=645527.657311>

11. Billsus, D., Pazzani, M.J.: User modeling for adaptive news access. *User Modeling and User-Adapted Interaction* 10(2-3), 147–180 (Feb 2000), <http://dx.doi.org/10.1023/A:1026501525781>
12. Boratto, L., Carta, S.: State-of-the-art in group recommendation and new approaches for automatic identification of groups. In: Soro, A., Vargiu, E., Armano, G., Paddeu, G. (eds.) *Information Retrieval and Mining in Distributed Environments, Studies in Computational Intelligence*, vol. 324, pp. 1–20. Springer Berlin Heidelberg (2011), http://dx.doi.org/10.1007/978-3-642-16089-9_1
13. Boratto, L., Carta, S., Chessa, A., Agelli, M., Clemente, M.L.: Group recommendation with automatic identification of users communities. In: *Proceedings of the 2009 IEEE/WIC/ACM International Joint Conference on Web Intelligence and Intelligent Agent Technology - Volume 03*. pp. 547–550. WI-IAT '09, IEEE Computer Society, Washington, DC, USA (2009), <http://dx.doi.org/10.1109/WI-IAT.2009.346>
14. Breese, J.S., Heckerman, D., Kadie, C.: Empirical analysis of predictive algorithms for collaborative filtering. In: *Proceedings of the Fourteenth Conference on Uncertainty in Artificial Intelligence*. pp. 43–52. UAI'98, Morgan Kaufmann Publishers Inc., San Francisco, CA, USA (1998), <http://dl.acm.org/citation.cfm?id=2074094.2074100>
15. Burke, R.: Hybrid recommender systems: Survey and experiments. *User Modeling and User-Adapted Interaction* 12(4), 331–370 (Nov 2002), <http://dx.doi.org/10.1023/A:1021240730564>
16. Burke, R.: The adaptive web. chap. *Hybrid Web Recommender Systems*, pp. 377–408. Springer-Verlag, Berlin, Heidelberg (2007), <http://dl.acm.org/citation.cfm?id=1768197.1768211>
17. Celma, Ò.: *Music Recommendation and Discovery in the Long Tail*. Ph.D. thesis, Universitat Pompeu Fabra, Barcelona (2008), static/media/PhD_ocelma.pdf
18. Chao, D.L., Balthrop, J., Forrest, S.: Adaptive radio: Achieving consensus using negative preferences. In: *Proceedings of the 2005 International ACM SIGGROUP Conference on Supporting Group Work*. pp. 120–123. GROUP '05, ACM, New York, NY, USA (2005), <http://doi.acm.org/10.1145/1099203.1099224>
19. Chien, Y.H., George, E.: A bayesian model for collaborative filtering. In: *Online Proceedings of the 7th International Workshop on Artificial Intelligence and Statistics* (1999)
20. Crossen, A., Budzik, J., Hammond, K.J.: Flytrap: Intelligent group music recommendation. In: *Proceedings of the 7th International Conference on Intelligent User Interfaces*. pp. 184–185. IUI '02, ACM, New York, NY, USA (2002), <http://doi.acm.org/10.1145/502716.502748>
21. Delgado, J., Ishii, N.: Memory-based weighted-majority prediction for recommender systems (1999)
22. Garcia, I., Sebastia, L., Onaindia, E., Guzman, C.: A group recommender system for tourist activities. In: *Proceedings of the 10th International Conference on E-Commerce and Web Technologies*. pp. 26–37. EC-Web 2009, Springer-Verlag, Berlin, Heidelberg (2009), http://dx.doi.org/10.1007/978-3-642-03964-5_4
23. Getoor, L., Sahami, M.: Using probabilistic relational models for collaborative filtering. In: *In Workshop on Web Usage Analysis and User Profiling (WEBKDD'99)* (1999)
24. Goldberg, D., Nichols, D., Oki, B.M., Terry, D.: Using collaborative filtering to weave an information tapestry. *Communications of the ACM* 35, 61–70 (1992)

25. Goldberg, K., Roeder, T., Gupta, D., Perkins, C.: Eigentaste: A constant time collaborative filtering algorithm. *Inf. Retr.* 4(2), 133–151 (Jul 2001), <http://dx.doi.org/10.1023/A:1011419012209>
26. Hanani, U., Shapira, B., Shoval, P.: Information filtering: Overview of issues, research and systems. *User Modeling and User-Adapted Interaction* 11(3), 203–259 (Aug 2001), <http://dx.doi.org/10.1023/A:1011196000674>
27. Hill, W., Stead, L., Rosenstein, M., Furnas, G.: Recommending and evaluating choices in a virtual community of use. In: *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*. pp. 194–201. CHI '95, ACM Press/Addison-Wesley Publishing Co., New York, NY, USA (1995), <http://dx.doi.org/10.1145/223904.223929>
28. Jameson, A.: More than the sum of its members: Challenges for group recommender systems. In: *Proceedings of the Working Conference on Advanced Visual Interfaces*. pp. 48–54. AVI '04, ACM, New York, NY, USA (2004), <http://doi.acm.org/10.1145/989863.989869>
29. Konstan, J.A., Miller, B.N., Maltz, D., Herlocker, J.L., Gordon, L.R., Riedl, J.: GroupLens: Applying collaborative filtering to usenet news. *Commun. ACM* 40(3), 77–87 (Mar 1997), <http://doi.acm.org/10.1145/245108.245126>
30. Lage, R., Durao, F., Dolog, P.: Towards effective group recommendations for microblogging users. In: *Proceedings of the 27th Annual ACM Symposium on Applied Computing*. pp. 923–928. SAC '12, ACM, New York, NY, USA (2012), <http://doi.acm.org/10.1145/2245276.2245456>
31. Lang, K.: NewsWeeder: learning to filter netnews. In: *Proceedings of the 12th International Conference on Machine Learning*. pp. 331–339. Morgan Kaufmann publishers Inc.: San Mateo, CA, USA (1995), <http://citeseer.ist.psu.edu/lang95newsweeder.html>
32. Lieberman, H., Van Dyke, N.W., Vivacqua, A.S.: Let's browse: A collaborative web browsing agent. In: *Proceedings of the 4th International Conference on Intelligent User Interfaces*. pp. 65–68. IUI '99, ACM, New York, NY, USA (1999), <http://doi.acm.org/10.1145/291080.291092>
33. Linden, G., Smith, B., York, J.: Amazon.com recommendations: Item-to-item collaborative filtering. *IEEE Internet Computing* 7(1), 76–80 (Jan 2003), <http://dx.doi.org/10.1109/MIC.2003.1167344>
34. Littlestone, N., Warmuth, M.K.: The weighted majority algorithm. *Inf. Comput.* 108(2), 212–261 (Feb 1994), <http://dx.doi.org/10.1006/inco.1994.1009>
35. Mahmood, T., Ricci, F.: Improving recommender systems with adaptive conversational strategies. In: *Proceedings of the 20th ACM Conference on Hypertext and Hypermedia*. pp. 73–82. HT '09, ACM, New York, NY, USA (2009), <http://doi.acm.org/10.1145/1557914.1557930>
36. Masthoff, J.: Group modeling: Selecting a sequence of television items to suit a group of viewers. *User Modeling and User-Adapted Interaction* 14(1), 37–85 (Feb 2004), <http://dx.doi.org/10.1023/B:USER.0000010138.79319.fd>
37. Masthoff, J.: Group recommender systems: Combining individual models. In: Ricci, F., Rokach, L., Shapira, B., Kantor, P.B. (eds.) *Recommender Systems Handbook*, pp. 677–702. Springer US (2011), http://dx.doi.org/10.1007/978-0-387-85820-3_21
38. McCarthy, J.F., Anagnost, T.D.: Musicfx: An arbiter of group preferences for computer supported collaborative workouts. In: *Proceedings of the 1998 ACM Conference on Computer Supported Cooperative Work*. pp. 363–372. CSCW '98, ACM, New York, NY, USA (1998), <http://doi.acm.org/10.1145/289444.289511>

39. McCarthy, J.F., Costa, T.J., Liongosari, E.S.: Unicast, outcast & groupcast: Three steps toward ubiquitous, peripheral displays. In: Proceedings of the 3rd International Conference on Ubiquitous Computing. pp. 332–345. UbiComp '01, Springer-Verlag, London, UK, UK (2001), <http://dl.acm.org/citation.cfm?id=647987.741333>
40. McCarthy, K., McGinty, L., Smyth, B., Salam, M.: The needs of the many: A case-based group recommender system. In: Proceedings of the 8th European Conference on Advances in Case-Based Reasoning. pp. 196–210. ECCBR'06, Springer-Verlag, Berlin, Heidelberg (2006), http://dx.doi.org/10.1007/11805816_16
41. McCarthy, K., Salam, M., Coyle, L., McGinty, L., Smyth, B., Nixon, P.: Cats: A synchronous approach to collaborative group recommendation. In: Sutcliffe, G., Goebel, R. (eds.) FLAIRS Conference. pp. 86–91. AAAI Press (2006), <http://dblp.uni-trier.de/db/conf/flairs/flairs2006.html#McCarthySCMSN06>
42. McSherry, F., Mironov, I.: Differentially private recommender systems: Building privacy into the net. In: Proceedings of the 15th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. pp. 627–636. KDD '09, ACM, New York, NY, USA (2009), <http://doi.acm.org/10.1145/1557019.1557090>
43. Miranda, N., Raminhos, R., Seabra, P., Sequeira, J., Gonçalves, T., Quaresma, P.: Reconhecimento de entidades nomeadas com svm. In: Actas das Jornadas de Informática da Universidade de Évora 2010 (Novembro 2010)
44. Miranda, N., Raminhos, R., Seabra, P., Sequeira, J., Gonçalves, T., Quaresma, P.: Named entity recognition using machine learning techniques. In: EPIA'11 – 15th Portuguese Conference on Artificial Intelligence. Lisbon, PT (October 2011)
45. Mooney, R.J., Roy, L.: Content-based book recommending using learning for text categorization. In: Proceedings of the Fifth ACM Conference on Digital Libraries. pp. 195–204. DL '00, ACM, New York, NY, USA (2000), <http://doi.acm.org/10.1145/336597.336662>
46. Nakamura, A., Abe, N.: Collaborative filtering using weighted majority prediction algorithms. In: Proceedings of the Fifteenth International Conference on Machine Learning. pp. 395–403. ICML '98, Morgan Kaufmann Publishers Inc., San Francisco, CA, USA (1998), <http://dl.acm.org/citation.cfm?id=645527.657289>
47. O'Connor, M., Cosley, D., Konstan, J.A., Riedl, J.: Polylens: A recommender system for groups of users. In: Proceedings of the Seventh Conference on European Conference on Computer Supported Cooperative Work. pp. 199–218. ECSCW'01, Kluwer Academic Publishers, Norwell, MA, USA (2001), <http://dl.acm.org/citation.cfm?id=1241867.1241878>
48. Pavlov, D.Y., Pennock, D.M.: A maximum entropy approach to collaborative filtering in dynamic, sparse, high-dimensional domains. In: In Proceedings of Neural Information Processing Systems. pp. 1441–1448. MIT Press (2002)
49. Pazzani, M., Billsus, D.: Learning and revising user profiles: The identification of interesting web sites. *Mach. Learn.* 27(3), 313–331 (Jun 1997), <http://dx.doi.org/10.1023/A:1007369909943>
50. Pazzani, M.J.: A framework for collaborative, content-based and demographic filtering. *Artif. Intell. Rev.* 13(5-6), 393–408 (Dec 1999), <http://dx.doi.org/10.1023/A:1006544522159>
51. Pirrone, R., Sorbello, F. (eds.): AI*IA 2011: Artificial Intelligence Around Man and Beyond - XIIth International Conference of the Italian Association for Artificial Intelligence, Palermo, Italy, September 15-17, 2011. Proceedings, Lecture Notes in Computer Science, vol. 6934. Springer (2011), <http://dx.doi.org/10.1007/978-3-642-23954-0>

52. Popescu, G.: Group recommender systems as a voting problem. In: Ozok, A., Zaphiris, P. (eds.) *Online Communities and Social Computing*, Lecture Notes in Computer Science, vol. 8029, pp. 412–421. Springer Berlin Heidelberg (2013), http://dx.doi.org/10.1007/978-3-642-39371-6_46
53. Popescu, G., Pu, P.: Probabilistic game theoretic algorithms for group recommender systems
54. Resnick, P., Iacovou, N., Suchak, M., Bergstrom, P., Riedl, J.: Grouplens: An open architecture for collaborative filtering of netnews. In: *Proceedings of the 1994 ACM Conference on Computer Supported Cooperative Work*. pp. 175–186. CSCW '94, ACM, New York, NY, USA (1994), <http://doi.acm.org/10.1145/192844.192905>
55. Resnick, P., Varian, H.R.: Recommender systems. *Commun. ACM* 40(3), 56–58 (Mar 1997), <http://doi.acm.org/10.1145/245108.245121>
56. Rich, E.: Readings in intelligent user interfaces. chap. *User Modeling via Stereotypes*, pp. 329–342. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA (1998), <http://dl.acm.org/citation.cfm?id=286013.286035>
57. Rocchio, J.J.: *Relevance feedback in information retrieval* (1971)
58. Salton, G. (ed.): *Automatic Text Processing*. Addison-Wesley Longman Publishing Co., Inc., Boston, MA, USA (1988)
59. Sarwar, B., Karypis, G., Konstan, J., Riedl, J.: Item-based collaborative filtering recommendation algorithms. In: *Proceedings of the 10th International Conference on World Wide Web*. pp. 285–295. WWW '01, ACM, New York, NY, USA (2001), <http://doi.acm.org/10.1145/371920.372071>
60. Schafer, J.B., Frankowski, D., Herlocker, J., Sen, S.: The adaptive web. chap. *Collaborative Filtering Recommender Systems*, pp. 291–324. Springer-Verlag, Berlin, Heidelberg (2007), <http://dl.acm.org/citation.cfm?id=1768197.1768208>
61. Schafer, J.B., Konstan, J.A., Riedl, J.: E-commerce recommendation applications. *Data Min. Knowl. Discov.* 5(1-2), 115–153 (Jan 2001), <http://dx.doi.org/10.1023/A:1009804230409>
62. Shani, G., Brafman, R.I., Heckerman, D.: An mdp-based recommender system. *CoRR* abs/1301.0600 (2013), <http://arxiv.org/abs/1301.0600>
63. Shardanand, U., Maes, P.: Social information filtering: Algorithms for automating “word of mouth”. In: *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*. pp. 210–217. CHI '95, ACM Press/Addison-Wesley Publishing Co., New York, NY, USA (1995), <http://dx.doi.org/10.1145/223904.223931>
64. Smyth, B., Balfe, E., Freyne, J., Briggs, P., Coyle, M., Boydell, O.: Exploiting query repetition and regularity in an adaptive community-based web search engine. *User Modeling and User-Adapted Interaction* 14(5), 383–423 (Jan 2005), <http://dx.doi.org/10.1007/s11257-004-5270-4>
65. Sprague, D., Wu, F., Tory, M.: Music selection using the partyvote democratic jukebox. In: *Proceedings of the Working Conference on Advanced Visual Interfaces*. pp. 433–436. AVI '08, ACM, New York, NY, USA (2008), <http://doi.acm.org/10.1145/1385569.1385652>
66. Terveen, L., Hill, W., Amento, B., McDonald, D., Creter, J.: Phoaks: A system for sharing recommendations. *Commun. ACM* 40(3), 59–62 (Mar 1997), <http://doi.acm.org/10.1145/245108.245122>
67. Ungar, L., Foster, D.: Clustering methods for collaborative filtering. In: *Proceedings of the Workshop on Recommendation Systems*. AAAI Press, Menlo Park California (1998), citeseer.ist.psu.edu/ungar98clustering.html
68. Yin, H., Cui, B., Li, J., Yao, J., Chen, C.: Challenging the long tail recommendation. *CoRR* abs/1205.6700 (2012), <http://arxiv.org/abs/1205.6700>

69. Yu, Z., Zhou, X., Hao, Y., Gu, J.: Tv program recommendation for multiple viewers based on user profile merging. *User Modeling and User-Adapted Interaction* 16(1), 63–82 (Mar 2006), <http://dx.doi.org/10.1007/s11257-006-9005-6>
70. Zhiwen, Y., Xingshe, Z., Daqing, Z.: An adaptive in-vehicle multimedia recommender for group users. In: *Vehicular Technology Conference, 2005. VTC 2005-Spring. 2005 IEEE 61st.* vol. 5, pp. 2800–2804 Vol. 5 (May 2005)