

## 5 Trabalhos Relacionados

### Filtragem Colaborativa

O processo de modelagem da informação em sistemas de recomendação envolve diversas áreas de conhecimento. Algumas dessas áreas, por exemplo, estudam a variabilidade nas avaliações dos usuários [48], a evolução nas relações entre os usuários de um conjunto de dados [49], informações fornecidas por usuários externos e especialistas [50], dimensões temporais [28, 51, 52] e o uso de informações espaço-temporais [53].

Um problema típico na pesquisa destes tipos de sistema é a impossibilidade de um usuário avaliar todos os itens disponíveis. Como descrito anteriormente, a consequência disso é que a matriz que relaciona os usuários aos itens acaba ficando com vários campos em branco. Algumas propostas tem sido consideradas na predição destas avaliações [54].

Nos casos de filtragem colaborativa a partir de dados implícitos a informação disponível corresponde às atividades dos usuários que podem ser rastreadas (por exemplo, a compra ou o *download* de um produto). Nestes casos é necessário incluir algum passo de pré-processamento dos dados, os quais tendem a ser binários (presença ou ausência de uma atividade, etc). Seguindo nesta linha, [55] sugere transformar informações temporais sobre o consumo de produtos em pseudo-avaliações. Outros [56, 57] usam informações sobre o quão freqüente cada item é consumido pelos usuários para criar avaliações que possam ser utilizadas como dados de entrada destes sistemas.

[60] considera crucial a utilização dos dados desconhecidos nas observações de comportamento dos usuários na utilização do *feedback* implícito dos usuários durante a montagem da matriz de avaliações, onde a maior parte das avaliações negativas tendem a ser encontradas. Dessa forma, as equações de atualização deveriam considerar todos os pares usuário-item, ao invés de apenas aqueles realmente observados. Este número de termos, que em alguns conjuntos de dados atingem a ordem de bilhões, impede o uso de técnicas de aprendizado com o gradiente descendente estocástico, o qual é amplamente utilizado no caso de conjunto de dados com *feedback* explícito. Também propõe que sejam

utilizadas outras métricas de avaliação que levem em conta a disponibilidade de um item, a competição de outros itens com relação ao primeiro, além de *feedbacks* repetidos. Por fim, compara um modelo de fatoração matricial com o resultado das recomendações geradas por algoritmos base que ordenam os vídeos mais populares dentro de um universo definido e algoritmos de vizinhança item-item.

Algumas abordagens sugerem o aprendizado do espaço latente na presença de dados do usuário, incorporando à equação de predição variáveis demográficas como o sexo e a idade dos mesmos [43]. Outras tentam entender o contexto atual dos usuários de forma a prover recomendações que se adéquem a situação atual dos usuários [44].

Herlocker, Konstan e Riedl [61] sugerem que boas recomendações devem vir acompanhadas com explicações, uma breve descrição com o por que de um produto em específico ter sido recomendado para um usuário. Isto ajuda a melhorar a confiança que os usuários têm no sistemas e a habilidade dos mesmos em colocar as recomendações na perspectiva correta. Além disso, auxilia na investigação de problemas no sistema, reduzindo a incidência de comportamentos inesperados no mesmo.

Durante os últimos anos, temos visto avanços [39, 40] na utilização de relações sociais juntamente com mecanismos de filtragem colaborativa na construção desses sistemas. Diferentes tecnologias baseadas em mineração de dados, aprendizado de máquina, inteligência artificial, entre outras, convergem neste contexto para melhor explorar as relações entre os usuários dos sistemas. Em [40] os autores sugerem que levar em consideração o contexto social e de familiaridade entre os usuários em suas avaliações auxilia na tomada de decisão e, conseqüentemente, em recomendações com mais qualidade. Em [39] os autores propõem um modelo que combina os laços sociais e as avaliações para aumentar a performance do sistema de recomendação dentro de uma rede social de avaliações, chegando a resultados interessantes.

Shepitsen [58] emprega um algoritmo de personalização para recomendação em folksonomia baseado numa clusterização hierárquica de *tags*.

Outros trabalhos focam em técnicas de passeio aleatório, sendo utilizados em diferentes áreas e se tornando casos de sucesso quando levadas para o campo das recomendações sociais [59].

Golbeck e Hendler [45] endereçaram o problema com uma abordagem baseada na confiança que uns usuários tem nos outros considerando de seus gostos. Eles utilizaram as declarações de confiança explicitadas no *site* de recomendações de filmes *FilmTrust* [46]. O *site* solicita que os usuários avaliem o nível de confiança que eles tem em outros usuários, indicando o gosto de quem eles pretendem seguir e o gosto de quem não seguir. A conclusão é que a confiança que uns usuários tem pelos outros é de grande valor para a qualidade das recomendações.

### Otimizações de Performance

Existe uma vasta gama de trabalhos relacionados a otimização em problemas de recomendação. Uma das primeiras abordagens que explorou a fatoração matricial para filtragem colaborativa foi [10]. Neste artigo, os autores observam que decompor uma matriz qualquer no produto de duas matrizes é uma tarefa de alto custo computacional e propõem o método de mínimos quadrados alternantes (*ALS*, do inglês *Alternating Least Square*).

Algoritmos baseados em *ALS* trabalham iterativamente e cada iteração consiste de dois estágios: no primeiro estágio a matriz  $P$  tem seus valores fixados e o problema de minimização do erro de predição  $\varepsilon_{ij}^2$  é resolvido com relação à matriz  $Q$ . No segundo estágio, ocorre o contrário. Em ambos os estágios, o problema pode ser reformulado e resolvido como um problema de mínimos quadrados (*LS*, do inglês *Least Square*) [10, 3]. Essas técnicas de *ALS* tem se mostrado altamente paralelizáveis. Assim, o crescimento contínuo das plataformas de computação paralela, como o *Hadoop* [42], tendem a ser de grande utilidade para rodar estes algoritmos.

Singh e Gordon [47] propõem uma forma de resolver múltiplas tarefas de fatoração matricial simultaneamente. Descrevemos resumidamente a idéia: suponhamos que temos duas matrizes (podendo estar com valores faltando), uma para a relação usuário-item, descrevendo como os usuários avaliam os itens ( $R$ ),

e outra para a relação item-data de consumo ( $S$ ). Podemos fatorar ambas as matrizes separadamente, e extrair o vetor de características dos itens decompondo  $R$ , e outro diferente extraindo  $S$ . A idéia é compartilhar os dois vetores de características dos itens e formular um novo problema de otimização combinando linearmente os dois vetores na equação do erro de predição a ser minimizada. A idéia poderia ser facilmente generalizada para fatorar qualquer quantidade de matrizes de forma simultânea.