

# 融合信任关系和有用性评价的矩阵分解推荐方法

曾安 徐小强

(广东工业大学计算机学院 广州 510006)

**摘要** 冷启动和数据稀疏性问题是推荐系统面临的两大难题。现有的大多数基于矩阵分解的推荐方法将用户孤立对待,忽略了用户之间的信任关系,导致推荐性能较低。提出一种融合信任关系和有用性评价的矩阵分解推荐方法。该方法在对评分矩阵进行概率分解的基础上,加入有用性评价和用户信任关系,采用交替最小二乘法训练模型参数。Epinions 和 Ciao 数据集上的对比实验表明,所提方法有效提高了推荐系统的准确性和可靠性,尤其存在冷启动用户时,该方法的推荐精度明显优于传统的推荐方法。

**关键词** 推荐系统,有用性评价,信任关系,矩阵分解

**中图分类号** TP311 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2017.04.059

## Using Social Trust Relationship and Helpfulness Ratings for Recommendation Based on Matrix Factorization

ZENG An XU Xiao-qiang

(School of Computer, Guangdong University of Technology, Guangzhou 510006, China)

**Abstract** So far, cold-start and data sparsity issues have still been two challenges in recommender systems. Most of traditional recommender systems based on the matrix factorization model often assumed that users are isolated and the relationships among users are ignored, this results in the decrease in the recommendation effects. Thus, a novel approach incorporating social trust relationship and helpfulness ratings was proposed. Based on the probabilistic matrix factorization, approach combined the social trust relationships among users with helpfulness ratings was proposed, and the alternating least squares was employed to train model parameters. The experiment results on Epinions and Ciao data set suggested that the proposed approach was superior to other advanced approaches in accuracy and reliability, especially while the cold-start issues were involved in.

**Keywords** Recommender system, Helpfulness ratings, Trust relationship, Matrix factorization

## 1 引言

个性化推荐系统作为缓解信息负载的有效手段,可通过分析用户的历史行为数据来获取用户的特征,把用户最可能感兴趣的内容主动推送给用户。然而随着用户数量的急剧增加,在有限行为数据条件下,构建用户兴趣模型和预测用户行为十分困难。矩阵分解方法旨在使用两个或者多个低维矩阵来逼近一个高维矩阵,这种方法能够删除噪声用户或噪声项目,把用户项目评分矩阵的维度降低,以取得用户和项目之间的潜在关系,从而获得较好的预测精度<sup>[1-3]</sup>,应用也较为广泛;并且,如果在矩阵分解的基础上融合边缘信息,将能够进一步缓解推荐系统面临的数据稀疏和冷启动问题<sup>[4-5]</sup>。

个性化推荐系统的关键数据源是用户历史行为数据。历史行为数据具体可分为两类:显式反馈(用户给出的显式倾向,如用户对项目的显式评分、用户对项目的喜爱或不喜爱等)和隐式用户反馈(用户对项目的评论、转发朋友圈、浏览时间等行为)。由于显式的反馈信息可能包含一些噪声,而用户

的隐式反馈却可以充分挖掘借以提高推荐的准确性<sup>[5]</sup>。传统的推荐方法只利用评分矩阵来产生推荐,它们仅仅关注用户的兴趣特征,将用户与用户的关系等同对待,忽略了用户间的信任关系。事实上,除了兴趣因素之外,用户间的信任关系在一定程度上也影响了用户的决策。有用性评价也隐式包含用户间的信任关系,因此,如果充分利用用户之间的相互影响来预测用户对未知项目的隐式偏好,必能在一定程度上缓解数据稀疏性对推荐系统性能的影响。但目前鲜有文献报道将用户信任关系和有用性评价两者有机结合的推荐模型。

于是,在用户项目评分矩阵的基础上,本文提出一种新颖的融合用户信任关系和隐式的用户有用性评论信息的矩阵分解方法。其中,用户信任关系显式表明用户之间的信任程度;用户有用性评论信息潜在表明用户之间的信任程度。这两方面的数据源能更好地挖掘用户之间的信任关系和预测用户的兴趣爱好。Epinions 和 Ciao 数据集上的实验结果表明,在数据趋于稀疏和存在冷启动用户的条件下,本文方法的推荐精度明显优于传统方法。

到稿日期:2016-03-21 返修日期:2016-07-11 本文受国家自然科学基金项目(61300107),广东省自然科学基金项目(S2012010010212),广州市科技计划项目(201504301341059),广东省科技计划项目(2014B090901053)资助。

曾安(1978-),女,博士,教授,主要研究方向为智能信息处理、数据挖掘,E-mail:zengan2010@126.com;徐小强(1987-),男,硕士生,主要研究方向为数据挖掘、推荐系统,E-mail:xxqcheers0614@163.com(通信作者)。

## 2 相关性研究

为了缓解评分稀疏对用户相似度计算的影响,一方面,有研究人员从用户社交关系<sup>[6-9]</sup>或用户之间的信任关系入手,构建社会化推荐模型;另一方面,也有人从用户对项目的评论或有用性评价信息入手<sup>[10-12]</sup>,由于显式的用户项目矩阵较为稀疏,因此这些评论信息可以看作是对显式评分数据缺失的一种补充。

### 2.1 融合用户社会关系

孟祥武等人<sup>[13]</sup>综述了最近几年社会化推荐系统的研究进展,比较了信任推理算法及社会化推荐中的关键技术和应用现状,提出了有效融合信任关系是社会化推荐领域中有待解决的难点之一。Hao M 等人<sup>[14-15]</sup>提出基于概率矩阵分解的因子分析方法,该方法融合了用户的社交网络信息和用户的评分矩阵,实验结果表明其预测精度比不考虑用户社交网络信息的情况有了显著提高;Tang J L 等人<sup>[10,16]</sup>从用户全局信任机制和局部信任机制两个方面细化用户之间的信任关系,并引入用户社会信任属性信息,在一定程度上缓解了推荐系统中的数据稀疏性和冷启动问题。从所查文献来看,虽然融合用户的显式信任关系能够提高推荐系统的精度,但是基于用户的这种信任的行为数据有时十分稀少。于是,一个很自然的思路是,如果能结合其他数据源(如用户的有用性评价信息)去充分挖掘用户之间的信任网络,那么对于一个新用户来说,只要网络中存在一个用户与此用户有直接或者间接的信任关系,就可以根据这种社会关系和已知用户兴趣对新用户产生推荐。

### 2.2 融合用户评论信息

在线评论(包括文本评论信息、有用性评价信息、点赞和踩等形式)在用户决策过程中扮演着一个重要的角色,其价值已经得到用户和在线零售商的公认。彭岚等人<sup>[11]</sup>对评论的有用性进行了深入研究,构建了一个评论有用性影响因素模型,指出评论蕴含的信息能够降低用户在线决策的不确定性。McAuley J<sup>[12]</sup>和 Yang B<sup>[17]</sup>等人结合用户评分信息,利用主题模型(如 LDA)产生推荐,通过这种方式,不仅能提高推荐系统的性能,而且能利用用户评论信息获取的主题来解释模型所推荐的项目。Wang S H 等人<sup>[18]</sup>从用户的双重角色出发,研究了在推荐模型中如何运用这两个角色来提高推荐系统精度和缓解冷启动问题。现实中,尽管用户文本评论或者有用性评价在一定程度上能够缓解数据稀疏问题,但是文本评论分析往往需要人工构造特定文本语料,数据噪声干扰也比较大。

综上所述,这两类模型虽然在一定程度上缓解了评分稀疏对用户相似度计算的影响,但仍存在一定的局限性,即融合用户社会信任关系将面临显式信任数据稀疏的挑战,而融合用户评论信息将带来较大的数据噪声干扰。此外,隐式信息范围广且易于收集,能够隐式地表达出用户间的信任关系,因此,如果能有效地融合反映用户间信任关系的隐式和显式信息,将能获得更好的效果。

### 2.3 冷启动问题描述

推荐系统中的冷启动问题分为新项目问题和新用户问题。新项目问题:一个未获得足够评价的新项目不易被推荐

出去。新项目问题常出现在不断增加新项目但用户仅对其中小部分做出评价的情况下。如果一个新项目没有人去评价它,或者都不去评价它,则这个项目肯定得不到推荐。这在协同推荐技术问题上表现得比较突出<sup>[20]</sup>。新用户问题:推荐系统中对用户分类的依据是目标用户与其他用户的比较,这种比较主要基于不断积累的用户评价,如果一个新用户未对系统中的项目进行评价,则系统无法获知他的兴趣点,也就无法对他进行推荐。

针对新项目问题,需要推荐系统引入一些新的机制来激励用户多做评价。而对新用户问题,有以下解决方案:推荐最热门的项目;花一段时间收集用户的数据(比如用户属性及用户的第三方社交关系数据),过一段时间后再予以分类和推荐。

## 3 融合有用性评价和信任关系的矩阵分解推荐方法

基于隐语义模型,本文在矩阵分解的基础上融合用户有用性评价信息和用户间的信任关系,这样,即使在用户项目评分稀疏的情况下,也能借助边缘数据更好地构造用户兴趣特征。

### 3.1 矩阵分解

矩阵因子分解的核心思想是假设用户的兴趣只受少数几个因素的影响,将稀疏且高维的用户项目评分矩阵分解为两个低维矩阵,即用户特征矩阵和项目特征矩阵。矩阵分解假设用户对项目的评分是通过用户的特征和项目的特征共同决定的,用户对项目最后的评分预测是由两个特征矩阵相乘得到的。

设  $U = [u_1, u_2, \dots, u_n] \in \mathbb{R}^{f \times n}$  代表用户的特征矩阵,  $V = [v_1, v_2, \dots, v_m] \in \mathbb{R}^{f \times m}$  代表项目的特征矩阵,这里的  $f$  表示特征向量的维度,其中  $n$  是用户的个数,  $m$  是项目的个数,  $f$  表示用户特征向量的维度。这里的特征矩阵可根据最小化式(1)中的损失函数获得:

$$Loss(U, V) = \min_{(u_i, v_j) \in O} \sum (R_{ij} - r_{ij})^2 + \lambda (\|U\|_F^2 + \|V\|_F^2) \quad (1)$$

$$r_{ij} = u + b_i + b_u + U_i^T V_j \quad (2)$$

$$b_u = b_u + \alpha * (R_{ij} - r_{ij} - \lambda * b_u) \quad (3)$$

$$b_i = b_i + \alpha * (R_{ij} - r_{ij} - \lambda * b_i) \quad (4)$$

其中,  $R_{ij}$  是用户项目评分矩阵中的非零评分,  $u$  是所有用户的评分均值,  $b_i$  和  $b_u$  分别代表项目和用户的偏置量。  $U_i$  是  $f$  维的用户特征向量,  $V_j$  是  $f$  维的项目特征向量。考虑了偏置项之后,计算公式和迭代方程都需要做相应的调整。用  $\alpha$  代表学习速率,  $\lambda$  是正则化系数。随着特征矩阵慢慢地更新,特征矩阵的乘积会慢慢逼近原始矩阵,与真实的误差越来越小。在更新迭代过程中,有可能会产生过度拟合的问题,通过在目标函数中增加一个正则项来避免该问题。

### 3.2 融合社会信任关系

社交网络的同质性理论<sup>[19]</sup>表明,具有相似特征的个体有选择彼此作为朋友的倾向,即所谓的“物以类聚,人以群分”。传统的协同过滤方法将用户之间的关系等同对待,无形之中会在构建用户模型时出现偏差。

使用余弦相似度来度量用户之间的信任强度  $S_{ij}$  (见式(5))。设  $T \in \mathbb{R}^{n \times n}$  代表用户之间的信任关系矩阵。  $T_{ij} = 1$  代

表用户  $u_i$  和用户  $u_j$  之间有信任关系,  $T_{ij}=0$  代表用户与用户之间未知关系, 比如针对用户  $u_i$ , 用集合  $\mathcal{N}=\{u_k | T(i,k)=1\}$  表示用户  $u_i$  的信任用户,  $m$  代表项目的数目。用  $S \in \mathbb{R}^{n \times n}$  代表用户之间的信任程度矩阵。对于  $u_j \in \mathcal{N}$ , 用户  $i$  和用户  $j$  的信任程度  $S_{ij}$  是通过用户  $u_i$  的评分向量和用户  $u_k$  的评分向量的余弦相似度来度量的。对于  $u_j \notin \mathcal{N}$ ,  $S_{ij}$  定义为零。

$$S_{ij} = \begin{cases} \frac{\sum_{k=1}^m R_{ik} * R_{jk}}{\sqrt{\sum_{k=1}^m R_{ik}^2} * \sqrt{\sum_{k=1}^m R_{jk}^2}}, & u_k \in \mathcal{N}_i \\ 0, & u_k \notin \mathcal{N}_i \end{cases} \quad (5)$$

将用户项目评分矩阵和用户之间的信任关系联合起来<sup>[16]</sup>的目标函数如式(6)所示:

$$Loss(U, V, P) = \min \sum_{R_{ij} \neq 0} (R_{ij} - u_i^T * v_j)^2 + \lambda \sum_{T_{ik} \neq 0} (S_{ik} - u_i^T P u_k)^2 + \lambda \Omega(\vartheta) \quad (6)$$

$$\Omega(\vartheta) = \|U\|_F^2 + \|V\|_F^2 + \|P\|_F^2 \quad (7)$$

其中,  $S_{ij}$  表示用户  $i$  和用户  $j$  的信任关联强度, 用户  $i$  的特征向量  $u_i$  和用户  $k$  的特征向量  $u_k$  是通过  $P \subseteq \mathbb{R}^{f \times f}$  关联在一起的, 矩阵  $P \subseteq \mathbb{R}^{f \times f}$  可以看作用户与用户之间信任矩阵  $S \subseteq \mathbb{R}^{n \times n}$  降维后的矩阵。若矩阵  $S$  中的元素  $S_{ik}$  值较大, 则表明用户  $u_i$  和用户  $u_k$  的信任关联性强;  $S_{ik}$  的值较小, 则表明用户  $u_i$  和用户  $u_k$  的信任关联性较弱。式(7)中  $\Omega(\vartheta)$  是正则项, 用于防止过拟合。

### 3.3 用户的有用性评价定义

Wang S H 等人的研究表明<sup>[18]</sup>: 用户对其他用户的评分给予评价时, 用户扮演的是双重角色, 其中一个角色表示直接对项目评分, 另一个角色表示对其他用户的评分进行有用性评价。这在一定程度上反映了当前用户直接或者间接对项目的爱好程度, 而且背后隐藏了用户之间的信任关系。为了便于说明问题, 构造如图 1 所示的场景来说明用户是如何扮演双重角色的。




图 1 用户项目交互图

如图 1 所示, 从有用性评价角度出发, 用户  $U_1$  对项目  $I_1$  的评分为  $r_1$ , 用户  $U_2$  不仅对项目  $I_1$  有评分  $r_2$ , 而且对来自用户  $U_1$  的评分  $r_1$  进行有用性评价(值为  $H_{21}$ ); 用户  $U_2$  对项目  $I_1$  的评分为  $r_2$ , 用户  $U_3$  仅对来自于用户  $U_2$  的评分  $r_2$  进行有用性评价(值为  $H_{32}$ ), 并没有对项目  $I_1$  评分。从信任关系角度出发, 用户  $U_2$  对用户  $U_1$  的信任值为  $T_2$ , 用户  $U_3$  对用户  $U_2$  的信任值为  $T_3$ , 用户  $U_1$  对用户  $U_3$  的信任值为  $T_1$ 。结合上述场景, 有如下 4 个定义<sup>[18]</sup>。

**定义 1 (Type-I Helpfulness)** 用户  $U_i$  针对其他用户对项目  $I_j$  的评分  $r_k$  (非  $U_i$  用户的评分) 具有有用性评价  $H_k$ , 而且用户  $U_i$  对项目  $I_j$  也有评分。

**定义 2 (Type-II Helpfulness)** 用户  $U_i$  仅针对其他用户对项目  $I_j$  的评分  $r_k$  (非  $U_i$  用户的评分) 具有有用性评价  $H_k$ , 然而用户  $U_i$  对项目  $I_j$  没有评分。

**定义 3** 集合  $P_{ij}$  表示用户  $U_i$  对项目  $I_j$  所有含有 Type-I Helpfulness 类型有用性评价的评分集合。

**定义 4** 集合  $K_{ij}$  表示用户  $U_i$  对项目  $I_j$  所有含有 Type-II Helpfulness 类型有用性评价的评分集合。

由定义 1 可知, 图 1 中的  $H_{21}$  属于 Type-I Helpfulness 类型的有用性评价; 由定义 2 可知,  $H_{32}$  和  $H_{33}$  属于 Type-II Helpfulness 类型的有用性评价。由定义 3 得到  $P_{21} = \{r_1\}$ , 因为  $U_2$  不仅对  $I_1$  有评分, 而且对  $r_1$  有有用性评价(其值为  $H_{21}$ );  $P_{31} = \emptyset$ , 因为  $U_3$  没有对项目  $I_1$  进行评分。类似地, 由定义 4 得到  $K_{21} = \emptyset$ , 因为  $U_2$  仅对  $I_1$  有评分;  $K_{31} = \{r_2\}$ , 因为  $U_3$  对  $I_1$  没有评分, 但是  $U_3$  对来自于  $U_2$  对  $I_1$  的评分  $r_2$  具有有用性评价(其值为  $H_{32}$ )。

基于以上分析, 用户  $U_i$  对项目  $I_j$  的评分为  $r_k$  (值为  $R_{ij}$ ),  $H_k$  设为  $U_i$  对评分  $r_k$  的有用性评价。那么,  $H_k$  间接表明  $U_i$  对  $I_j$  的喜爱程度,  $r_k$  (值为  $R_{ij}$ ) 直接表明  $U_i$  对  $I_j$  的喜爱程度,  $H_k$  和  $R_{ij}$  可以联合在一起用来量化  $U_i$  对  $I_j$  的喜爱程度。这里构造函数  $\psi(H_k, R_{ij})$  来获得用于反映  $H_k$  和  $R_{ij}$  两方面因素的特征向量, 然后再借助线性回归模型, 设  $w$  为特征向量的映射系数, 进而获得用户  $U_i$  对项目  $I_j$  的综合评分  $\psi(H_k, R_{ij})^T * w$ 。这里取  $\psi(x, y)$  为:

$$\psi(x, y) = [x; y; x * y; x^2; y^2; \frac{1}{x}; \frac{1}{y}]$$

该函数是用  $x$  和  $y$  定义特征比, 如设  $H_{21} = 4, R_{21} = 5$ , 则  $\psi(4, 5)$  为:

$$\psi(4, 5) = [4; 5; 20; 16; 25; \frac{1}{4}; \frac{1}{5}]$$

基于这种方式, 可构造如下的目标函数:

$$Loss = \min \sum_{i=1}^n \sum_j^m F_{ij} (\frac{1}{|P_{ij}|} \sum_{k \in P_{ij}} \psi(H_k, R_{ij})^T w - R_{ij})^2 + \beta \sum_{i=1}^n \sum_j^m G_{ij} (\frac{1}{|K_{ij}|} \sum_{k \in K_{ij}} \psi(H_k, R_{ij})^T w - u_i^T v_j)^2 \quad (8)$$

其中,  $F_{ij}$  和  $G_{ij}$  在这里所起的作用是标记,  $|P_{ij}|$  是集合  $P_{ij}$  中元素的数目,  $|K_{ij}|$  是集合  $K_{ij}$  中元素的数目。  $\psi(x, y)$  是有用性评价的函数所映射的特征向量,  $w$  表示特征向量的系数,  $\psi(H_k, R_{ij})^T w$  是 Type-I Helpfulness 的预测评分,  $R_{ij}$  是实际的评分,  $\psi(H_k, R_{ij})^T w$  代表的是 Type-II Helpfulness 的预测评分,  $u_i^T v_j$  是用户特征向量和项目特征向量的乘积。

$$F_{ij} = \begin{cases} 1, & |P_{ij}| > 0 \\ 0, & |P_{ij}| = 0 \end{cases} \quad (9)$$

$$G_{ij} = \begin{cases} 1, & |K_{ij}| > 0 \\ 0, & |K_{ij}| = 0 \end{cases} \quad (10)$$

式(8)所示的目标函数中, 第一项表示的是基于 Type-I Helpfulness 类型的有用性评价的属性获得, 第二项表示的是基于 Type-II Helpfulness 类型的有用性评价的属性获得。

### 3.4 DualSocTrust: 融合有用性评价和信任关系的矩阵分解算法

综合用户社会关系的目标函数(见式(6))和用户有用性评价信息的目标函数(见式(8)), 构建如式(11)所示的目标函数:

$$Loss(U, V, P) = \min \sum_{i=1}^n \sum_{j=1}^m I_{ij} (R_{ij} - u_i^T v_j)^2 + \mu \sum_{\tau_k \neq 0} (S_k - u_i^T P u_k)^2 + \alpha \sum_{i=1}^n \sum_{j=1}^m F_{ij} \left( \frac{1}{|P_{ij}|} \sum_{k \in P_{ij}} \psi(H_{ik}, R_{ij})^T w - R_{ij} \right)^2 + \beta \sum_{i=1}^n \sum_{j=1}^m G_{ij} \left( \frac{1}{|Q_{ij}|} \sum_{k \in Q_{ij}} \psi(H_{ik}, R_{ij})^T w - u_i^T v_j \right)^2 + \gamma (\|U\|_F^2 + \|V\|_F^2 + \|P\|_F^2) + \lambda (\|w\|_2^2) \quad (11)$$

其中,第一项来源于矩阵分解模型;第二项代表的是用户的社会信任关系;第二项和第三项代表的是将用户的评分信息和对评分的评价双重角色;第四项为正则项,用于防止过拟合。

为了最小化,本文采用了 Alternating Least Squares (ALS)算法。ALS算法是基于矩阵分解模型常用的求解算法,而且能够很好地并行处理。此时,需要求解 4 个梯度,为了求  $U$  和  $V$  的梯度,移除不相关的变量,获得式(12):

$$L(U, V) = \|I \odot (U^T V - R)\|_F^2 + \gamma (\|U\|_F^2 + \|V\|_F^2) + \beta \|G \odot (U^T V - M)\|_F^2 \quad (12)$$

其中,  $\odot$  代表的是 Hadamard product。为了后续描述的方便,将式(13)简写为了式(12)中的  $M$ 。

$$M_{ij} = \begin{cases} \frac{1}{|Q_{ij}|} \sum_{k \in Q_{ij}} \psi(H_{ik}, R_{ij})^T w, & \text{if } G_{ij} > 0 \\ 0, & \text{otherwise} \end{cases} \quad (13)$$

通过求目标函数偏导函数,得到如下梯度函数:

$$\frac{\partial L(U, V)}{\partial U} = 2V(I \odot (U^T V - R))^T + 2\gamma U + 2\beta V(G \odot (U^T V - M))^T \quad (14)$$

$$U = U - \epsilon \frac{\partial L(U, V)}{\partial U}$$

其中,  $\epsilon$  代表学习速率。

类似地,有:

$$\frac{\partial L(U, V)}{\partial V} = 2U(I \odot (U^T V - R))^T + 2\gamma V + 2\beta U(G \odot (U^T V - M))^T \quad (15)$$

$$V = V - \epsilon \frac{\partial L(U, V)}{\partial V} \quad (16)$$

$$\frac{\partial L(P)}{\partial P} = \mu \sum_{\tau_k \neq 0} (U_i^T P u_k - S_k) U_i U_k^T + \gamma P \quad (17)$$

$$P = P - \epsilon \frac{\partial L(P)}{\partial P} \quad (18)$$

除去不相关的项,得到式(19):

$$L(w) = \alpha \sum_{i=1}^n \sum_{j=1}^m F_{ij} \left( \frac{1}{|P_{ij}|} \sum_{k \in P_{ij}} \psi(H_{ik}, R_{ij})^T w - R_{ij} \right)^2 + \beta \sum_{i=1}^n \sum_{j=1}^m G_{ij} \left( \frac{1}{|Q_{ij}|} \sum_{k \in Q_{ij}} \psi(H_{ik}, R_{ij})^T w - u_i^T v_j \right)^2 + \lambda \|w\|_2^2 \quad (19)$$

为了方便计算,给出如下两个公式:

$$x_{ij} = \frac{1}{|P_{ij}|} \sum_{k \in P_{ij}} \psi(H_{ik}, R_{ij})^T \quad (20)$$

$$z_{ij} = \frac{1}{|Q_{ij}|} \sum_{k \in Q_{ij}} \psi(H_{ik}, R_{ij})^T \quad (21)$$

求得偏导数之后,令其为零,从而获得对于  $w$  的梯度:

$$\frac{\partial L(w)}{\partial w} = 2\alpha \sum_{i=1}^n \sum_{j=1}^m F_{ij} x_{ij} (x_{ij}^T w - R_{ij}) + 2\beta \sum_{i=1}^n \sum_{j=1}^m G_{ij} z_{ij} (z_{ij}^T w - u_i^T v_j) + 2\lambda w \quad (22)$$

DualSocTrust 算法描述如下。

输入:用户项目的评分矩阵  $R \subseteq \mathbb{R}^{n \times m}$ ;用户对评分数据的有用性评价矩阵  $H \subseteq \mathbb{R}^{n \times N}$ ;用户之间的信任关系矩阵  $T \subseteq \mathbb{R}^{n \times n}$

输出:目标用户  $u$  对项目  $i$  的预测评分值

步骤 1 计算所有评分的平均值  $u$ ,分别利用式(3)和式(4)计算用户偏置量  $b_u$  和项目偏置量  $b_i$ ,针对每一用户随机初始化用户和项目的特征向量  $U_i, V_j$  和  $w$  向量。

步骤 2 循环迭代用户的评分矩阵  $R$ 、用户有用性评价矩阵  $H$ ,根据定义 1、定义 2 构造 Type-I Helpfulness 和 Type-II Helpfulness 组成的集合。

for  $i=1$  to  $n$  do

for  $j=1$  to  $m$  do

根据定义 3 构造  $P_{ij}$

根据定义 4 构造  $Q_{ij}$

end for

end for

步骤 3 判断迭代指标是否收敛,如果收敛,则利用用户的特征向量和项目的特征向量计算用户对项目的预测评分  $R=U^T V$ ;否则,循环执行步骤 4。

步骤 4

步骤 4.1 使用式(13)计算矩阵  $M$ ;

步骤 4.2 使用式(14)计算  $\frac{\partial L(U, V)}{\partial U}$ ;

步骤 4.3 更新用户特征向量  $U$ ;

步骤 4.4 使用式(15)计算  $\frac{\partial L(U, V)}{\partial V}$ ;

步骤 4.5 更新项目特征向量  $V$ ;

步骤 4.6 使用式(18)计算  $\frac{\partial L(P)}{\partial P}$ ;

步骤 4.7 更新  $\frac{\partial L(P)}{\partial P}$ ;

步骤 4.8 更新  $w$  向量。

## 4 实验结果及分析

### 4.1 数据集和实验参数设置

本文采用了 Epinions 和 Ciao 数据集进行验证,这两个数据集提供了用户对项目的评分信息、用户和用户之间的信任关系以及用户对其他用户评分的有用性评价。数据集中评分值为 1~5 之间的整数,分数越高表示用户对项目的评价越高,每一个用户维护一个信任列表。对原始数据集进行清洗,剔除对项目评分很少的用户(少于 5 个项目)和拥有很少评论(少于 6)的项目。数据集的基本情况如表 1 所列。

表 1 数据集统计

数据集名称	Epinions	Ciao
用户数目	4362	4694
项目数目	5633	6036
评分数目	131701	120982
评分密度	0.00536	0.00427
社会关系数目	3168	20271
社会关系密度	0.00016	0.00092
H, R 总数目	864958	1124638
Type-I H, R 数目	64231	159384
Type-II H, R 数目	800727	965254

表 1 中,评分密度指的是在评分矩阵中有评分的项占矩阵全部项的比例,比例越低说明数据集越稀疏。除此之外,为了验证该模型处理稀疏性数据集的表现性能,将训练集设置

为10%,20%,40%作为对比。

预测准确度是目前推荐系统研究中讨论得比较多的属性。本文采用评分预测准确度评测。均方根误差(RMSE)和评价绝对误差(MAE)是评分预测中比较流行的度量。系统在已知用户项目集合 $(i, j)$ 真实评分 $R_{ij}$ 的情况下,在测试集 $T$ 上生成预测评分 $r_{ij}$ 。预测评分与实际评分间的RMSE、MAE的计算如下:

$$MAE = \frac{\sum_{(i,j) \in T} |R_{ij} - r_{ij}|}{|T|} \quad (23)$$

$$RMSE = \sqrt{\frac{\sum_{(i,j) \in T} (R_{ij} - r_{ij})^2}{|T|}} \quad (24)$$

上述评测指标定义中的 $T$ 代表的是所要预测的评分集合, $R_{ij}$ 为用户 $u_i$ 给予 $v_j$ 项目的评分, $r_{ij}$ 为预测评分。

#### 4.2 实验结果比较

为了验证文中所提算法的性能,本文将DualSocTrust算法与PMF算法<sup>[2]</sup>(Probabilistic Matrix Factorization, PMF)、DualRec算法<sup>[18]</sup>(Toward Dual Roles of Users in Recommender Systems, DualRec)和SocRec算法<sup>[14]</sup>(Social Recommendation Using Probabilistic Matrix Factorization, SocRec)在Epinions和Ciao数据集上进行比较。PMF仅仅基于评分矩阵,将用户之间的关系孤立对待,认为所有用户之间的关系是等同的;DualRec在用户项目评分矩阵的基础上考虑用户的隐式反馈有用性评价信息,但是并没有充分利用用户的信任列表;SocRec在评分矩阵的基础上考虑了用户之间的社会关系属性,但是忽略了有用性评价所反映的用户双重角色。

在整个实验过程中, $\alpha=0.01, \beta=0.001, \mu=0.01$ ,正则化参数设置: $\gamma=0.1, \lambda=1$ ,特征向量的维数设为10。实验统计结果如表2、表3所列。其中表2采用的评测指标是RMSE,表3采用的评测指标是MAE。

表2 RMSE作为评测指标的结果

数据集	Training Size/%	PMF	SocRec	DualRec	DualSocTrust
Epinions	10	1.2472	1.1707	1.1462	1.1165
	20	1.1962	1.1331	1.1182	1.1023
	40	1.1567	1.1033	1.0935	1.0877
	80	1.1392	1.0867	1.0784	1.0631
Ciao	10	1.1957	1.1458	1.1195	1.0793
	20	1.1464	1.1098	1.0925	1.0658
	40	1.1049	1.0839	1.0678	1.0515
	80	1.0773	1.0675	1.0531	1.0281

表3 MAE作为评测指标的结果

数据集	Training Size/%	PMF	SocRec	DualRec	DualSocTrust
Epinions	10	0.9431	0.9162	0.9017	0.8752
	20	0.9176	0.8915	0.8832	0.8667
	40	0.8933	0.8706	0.8644	0.8587
	80	0.8831	0.8618	0.8564	0.8483
Ciao	10	0.9346	0.9047	0.8858	0.8571
	20	0.8967	0.8757	0.8641	0.8464
	40	0.8671	0.8525	0.8446	0.8351
	80	0.8536	0.8384	0.8295	0.8211

纵向分析表2、表3,可以看出在训练数据集取原始数据集规模10%,20%,40%,80%的情况下,本文提出的Dual-

SocTrust的MEA值与RMSE值比其他方法的MAE值与RMSE值都要小,即预测的准确性更高。横向分析表2、表3,训练数据集相对比较稀疏时,DualSocTrust与其他3个算法相比,相对于PMF提高幅度最大,SocRec其次,DualRec最小。比如针对Epinions数据集,RMSE作为评测指标时,在训练数据集规模为10%时,DualSocTrust相对于PMF,SocRec,DualRec分别提高了10.50%,4.66%,2.62%。之所以会出现这种区别,是因为PMF仅从用户项目评分矩阵数据源出发,等同对待所有用户间的关系,忽略了用户间社会属性的影响;SocRec在评分矩阵的基础上融合了用户之间的信任关系,但没有考虑用户有用性评价这些隐式反馈数据,而这种隐式反馈数据所反映的用户双重角色能够对构建用户和项目的特征矩阵起到修正作用,并且用户的双重角色背后隐藏了潜在的用户信任关系;DualRec虽然将用户的有效评价所表现的双重角色考虑在内,但是却忽略了用户之间的显式信任关系;DualSocTrust既考虑了显式的用户信任关系,又融合了用户双重角色隐含的潜在信任关系,这两方面的数据源能更好地挖掘用户之间的信任关系。

为了检验在数据较稀疏情况下DualSocTrust模型的稳定性,针对Epinions数据集,将其规模分别设置为10%,20%和40%时,实验结果如图2、图3所示。其中图2的评测指标是RMSE,图3的评测指标是MAE。从图中可以看出,在训练数据集倾向于稀疏的情况下,DualSocTrust曲线的倾斜程度是最小的,SocRec的倾斜程度相对于PMF也较小。通过这种现象可以看出,融合用户信任关系和用户评价等边缘信息能够缓解数据稀疏时所造成的推荐精度不高的问题,这与文献<sup>[5,12,15]</sup>得出的结论也是相符的。




图2 Epinions数据集下RMSE作为评测指标的结果




图3 Epinions数据集下MAE作为评测指标的结果

为了验证该模型处理冷启动问题的表现情况,实验针对10%,20%,40%,80%的训练集,在每个训练集中随机选择5%的用户,将评分矩阵对应的评分值移除,但是保留用户之间的信任关系属性和用户的有效评价信息。实验统计结果如表4、表5所列。其中表4采用的评测指标是RMSE,表5采用的评测指标是MAE。

表4 带冷启动用户 RMSE 作为评测指标的结果

数据集	Training Size/%	PMF	SocRec	DualRec	DualSocTrust
Epinions	10	1.2849	1.1973	1.1713	1.1342
	20	1.2367	1.1605	1.1401	1.1161
	40	1.2036	1.1335	1.1145	1.1039
	80	1.1891	1.1171	1.1034	1.0808
Ciao	10	1.2331	1.1713	1.1421	1.0972
	20	1.1849	1.1363	1.1132	1.0795
	40	1.1421	1.1131	1.0888	1.0657
	80	1.1235	1.0976	1.0761	1.0445

表5 带冷启动用户 MAE 作为评测指标的结果

数据集	Training Size/%	PMF	SocRec	DualRec	DualSocTrust
Epinions	10	0.9764	0.9386	0.9237	0.8921
	20	0.9549	0.9155	0.9042	0.9001
	40	0.9379	0.8953	0.8828	0.8753
	80	0.9265	0.8879	0.8774	0.8669
Ciao	10	0.9676	0.9269	0.9072	0.8732
	20	0.9331	0.8993	0.8829	0.8591
	40	0.9099	0.8764	0.8625	0.8514
	80	0.8949	0.8635	0.8497	0.8388

通过观察表4、表5可知,当训练数据集的规模设置为10%,20%,40%时,在选定数据集规模下随机移除5%的用户的项目评分,可看到PMF下降幅度最大,SocRec和DualRec相差不多,DualSocTrust下降幅度最小。比如在Epinions数据集下,在训练数据集为10%时,RMSE作为评测指标,PMF下降2.93%,SocRec下降2.22%,DualRec下降2.14%,DualSocTrust下降1.56%;MAE作为评测指标,PMF下降3.41%,SocRec下降2.39%,DualRec下降2.36%,DualSocTrust下降1.84%。这是因为在移除评分项后,SocRec,DualRec可以借助于用户的信任关系和用户的有用性评价这些数据源来修正用户和项目的特征矩阵。而DualSocTrust不仅可以利用用户的信任关系,而且可以利用用户的有用性评价所反映的双重角色,因此DualSocTrust有效缓解了冷启动带来的推荐精度低的问题。

#### 4.3 模型参数的选择

为了衡量用户信任关系和用户有用性评价双重角色的权重对实验结果的影响,固定用户和项目的特征向量的维数为10。为了选择模型中3个参数 $\mu$ 、 $\alpha$ 和 $\beta$ 的最优值,针对不同的参数进行大量的实验,根据直观感知给予显式评分较大权重,给予隐式评分给予较小权重。针对一个参数,首先固定另外两个模型参数,将其采用倍增的方式进行调节,由最终的实验结果看出:算法的推荐精度逐渐增大,但是到一定程度后反而下降。因此选择比较有代表性的7组实验数据来说明模型参数选优的过程。实验结果如图4所示。




图4 模型参数选择

图4中 $\mu$ 的变化范围为 $\{1, 0.1, 0.01, 0.001, 0.0001\}$ ,  $\alpha$ 的变化范围为 $\{0.1, 0.01, 0.001\}$ ,  $\beta$ 的变化范围为 $\{0.1, 0.01, 0.001\}$ 。通过观察可知,在 $\alpha=0.01, \beta=0.001, \mu=0.01$ 的情况下,能够获得较好的性能,而且相对稳定。在训练模型时, $\mu$ 用来衡量用户信任关系的权重, $\alpha$ 和 $\beta$ 分别衡量 Type-I Helpfulness 和 Type-II Helpfulness 类型的权重。从图4中可以看出,在调整参数的过程中,往往倾向于对用户直接给定的项目评分赋予较大权重,而对隐式获得的评分赋予较小权重。在本数据集中,通过观察可知,当 $\alpha=0.01, \beta=0.001, \mu=0.01$ 时,能够获得较好的性能,而且相对稳定。

**结束语** 本文针对推荐系统中的数据稀疏性问题和冷启动问题,提出了一种融合用户有用性评价信息和用户之间信任关系的基于矩阵分解的协同过滤算法,即DualSocTrust算法。相对于传统的单纯利用用户项目评分信息而言,DualSocTrust算法能充分挖掘用户特征。最后,在Epinions和Ciao数据集上验证了该推荐算法的推荐精度和可行性。实验结果表明,在数据比较稀疏的情况下,融合用户有用性评价和用户信任关系能够提高推荐精度,而且该方法能够有效缓解推荐系统面临的冷启动问题。针对用户评论而言,用户的文本评论信息也是一种重要的数据源,因此如何融合用户文本评论信息将是下一步的研究重点。

#### 参考文献

- [1] TAKÁCS G, PILÁSZY I, NEMETH B, et al. Investigation of various matrix factorization methods for large recommender systems[C] // IEEE International Conference on Data Mining Workshops, 2008 (ICDMW'08). IEEE, 2008.
- [2] MNIH A, SALAKUTDINOV R. Probabilistic matrix factorization[C] // Advances in Neural Information Processing Systems. 2007; 1257-1264.
- [3] LI P P, XIAO R L, DENG X G, et al. A Novel Approach to Matrix Factorization Recommender System Using Gravitational Impacts[J]. Journal of Chinese Computer Systems, 2015, 36(4): 696-700. (in Chinese)  
李鹏澎,肖如良,邓新国,等.一种融合引力影响的新的矩阵分解推荐方法[J].小型微型计算机系统,2015,36(4):696-700.
- [4] TU D D, SHU C C, YU H Y. Using Unified Probabilistic Matrix Factorization for Contextual Advertisement Recommendation [J]. Journal of Software, 2013, 24(3): 454-464. (in Chinese)  
涂丹丹,舒承椿,余海燕.基于联合概率矩阵分解的上下文广告推荐算法[J].软件学报,2013,24(3):454-464.
- [5] WANG D, CHEN Z, YUE W J, et al. Probabilistic matrix factorization recommendation with explicit and implicit feedback [J]. Journal of Computer Applications, 2015, 35(9): 2574-2578. (in Chinese)  
王东,陈志,岳文静,等.基于显式与隐式反馈信息的概率矩阵分解推荐[J].计算机应用,2015,35(9):2574-2578.
- [6] JAMALI M, ESTER M. A matrix factorization technique with trust propagation for recommendation in social network[C] // Proc of the ACM Recommender Systems Conf. New York: ACM Press, 2010.
- [7] MASSA P, AVESANI P. Trust-aware collaborative filtering for recommender systems[J]. Lecture Notes in Computer Science,

- 2004, 3290:492-508.
- [8] VINCENT S Z, BOI F. Using hierarchical clustering for learning the ontologies used in recommendation systems[C]// Proceedings of the 13th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Jose, California, United States, 2007.
- [9] ZOU B Y, LI C P, TAN L W, et al. Social Recommendations Based on User Trust and Tensor Factorization[J]. Journal of Software, 2014, 25(12):2852-2864. (in Chinese)  
邹本友, 李翠平, 谭力文, 等. 基于用户信任和张量分解的社会网络推荐[J]. 软件学报, 2014, 25(12):2852-2864.
- [10] TANG J L, GAO H J, HU X, et al. Context-Aware Review Helpfulness Rating Prediction[C]// RecSys'13. 2013.
- [11] PENG L, ZHOU Q H, QIU J T. Research on the Model of Helpfulness Factors of Online Customer Reviews[J]. Computer Science 2011, 38(8):205-207. (in Chinese)  
彭岚, 周启海, 邱江涛. 消费者在线评论有用性影响因素模型研究[J]. 计算机学报, 2011, 38(8):205-207.
- [12] MCAULEY J, FRIEDKIN J. Hidden factors and hidden topics: understanding rating dimensions with review text[C]// RecSys. 2013.
- [13] MENG X W, LIU S D, ZHANG Y J, et al. Research on Social Recommender Systems[J]. Journal of Software, 2015, 26(6):1356-1372. (in Chinese)  
孟祥武, 刘树栋, 张玉洁, 等. 社会化推荐系统研究[J]. 软件学报, 2015, 26(6):1356-1372.
- [14] MA H, YANG H X, LYU M R, et al. Sorec: Social recommendation using probabilistic matrix factorization[C]// CIKM. 2008.
- [15] MA H, ZHOU D, LIU C, et al. Recommender systems with social regularization[C]// WSDM. 2011.
- [16] TANG J L, HU X, GAO H J, et al. Exploiting local and global social context for recommendation[C]// IJCAI. 2013.
- [17] YANG B, HUI F, JIE Z. Topicmf: Simultaneously exploiting ratings and reviews for recommendation[C]// AAAI. 2014
- [18] WANG S H, TANG J L, LIU H. Toward Dual Roles of Users in Recommender Systems[C]// CIKM. 2015.
- [19] MCPHERSON M, SMITH-LOVIN L, COOK J M. Birds of a feather: Homophily in social networks[J]. Annual Review of Sociology, 2001, 27(1):415-444.
- [20] YU L, LIU L, LUO Z H. Comparison and Analysis on E-Commerce Recommendation Method in China[J]. System Engineering Theory and Practice, 2004, 24(8):96-101. (in Chinese)  
余力, 刘鲁, 罗掌华. 我国电子商务推荐策略的比较分析[J]. 系统工程理论与实践, 2004, 24(8):96-101.

(上接第 262 页)

分, 它研究的是如何按照论辩式程序来判定给定论辩语义中某个论证的证成状态。本文在前期工作<sup>[6]</sup>的基础上定义了一种 BRD-论辩语义, 这是一种满足排除合理怀疑标准的渐进式论辩语义, 较传统的扩充和标记论辩语义有若干优点。为说明该模型的可行性, 本文还应用该语义分析了一个案例。本文的创新工作在于, 为给出该语义的证明理论, 构建了一种论证博弈模型, 并证明了其完全性和可靠性。在另一种 PE-论辩语义中, 要求被证成的论证满足优势证据标准, 正反双方具有对称的证明责任, 这意味着双方都可以减弱或击败对方的论证。下一步的研究工作将建构对应的论证博弈模型, 给出 PE-论辩语义的证明理论。

### 参考文献

- [1] DUNG P M. On the Acceptability of Arguments and its Fundamental Role in Nonmonotonic Reasoning, Logic Programming and N-person Games[J]. Artificial Intelligence, 1995, 77(2):321-357.
- [2] CAMINADA M, AMGOUD L. On the Evaluation of Argumentation Formalisms[J]. Artificial Intelligence, 2007, 171(5/6):286-310.
- [3] PRAKKEN H. An Abstract Framework for Argumentation with Structured Arguments[J]. Argument and Computation, 2010, 3(1):93-124.
- [4] MODGIL S J, PRAKKEN H. A General Account of Argumentation with Preferences [J]. Artificial Intelligence, 2013, 195(195):361-397.
- [5] Most Cited Artificial Intelligence Articles [OL]. [2016-11-20].  
<http://www.journals.elsevier.com/artificial-intelligence/most-cited-articles>.
- [6] BIN W, PRAKKEN H. An Analysis of Critical-link Semantics with Variable Degrees of Justification[J]. Argument and Computation, 2016, 7(1):35-53.
- [7] AMGOUD L, CAYROL C, LAGASQUIE C, et al. On Bipolarity in Argumentation Frameworks[J]. International Journal of Intelligent Systems, 2008, 23(10):1062-1093.
- [8] POLLOCK J L. Defeasible Reasoning with Variable Degrees of Justification[J]. Artificial Intelligence, 2002, 133(1/2):233-282.
- [9] GORDON T F, WALTON D. Proof Burdens and Standards [M]// Rahwan I, Simari G R, eds. Argumentation in Artificial Intelligence. Springer, 2009:239-260.
- [10] JAKOBOVITS H, VERMEIR M. Robust Semantics for Argumentation Frameworks[J]. Journal of Logic and Computation, 1999, 9(2):215-261.
- [11] GAMINADA M, GABBAY D. A Logical Account of Formal Argumentation[J]. Studia Logica, 2009, 93(2/3):109-145.
- [12] WU Y N, CAMINADA M. A Labelling-Based Justification Status of Arguments[J]. Studies in Logic, 2010, 3(4):12-29.
- [13] 潘伟斌. 曹操墓的考古学证明[N]. 中国社会科学报, 2011-11-22(08).
- [14] DUNG P M, KOWALSKI R A, TONI F. Dialectic Proof Procedures for Assumption-based, Admissible Argumentation [J]. Artificial Intelligence, 2006, 170(2):114-159.
- [15] VREESWIJK G, PRAKKEN H. Credulous and Sceptical Argument Games for Preferred Semantics[C]// Proceedings of the 7th European Workshop on Logic for Artificial Intelligence (JELIA-00). Springer, 2000:239-253.