

社会网络环境下的协同推荐方法

李慧^{1,2*}, 胡云^{1,3}, 施珺¹

(1. 淮海工学院 计算机工程学院, 江苏 连云港 222001; 2. 中国矿业大学 信息与电气工程学院, 江苏 徐州 221008;

3. 南京大学 计算机科学与技术系, 江苏 南京 210000)

(* 通信作者电子邮箱 shufanzs@126.com)

摘要:针对传统协同过滤推荐算法的数据稀疏性及恶意评分等问题,提出了一种融合信任度与矩阵分解技术实现社会网络推荐的方法。首先通过计算节点的声望值与偏见值发现网络中的不可信节点,并将其评分权重进行弱化。然后将用户-评分矩阵与信任度矩阵相结合,实现社会网络环境下的协同推荐。实验表明,相对于传统的协同过滤算法,该算法可以消减虚假评分或恶意评分给推荐系统带来的负面影响,有效地缓解数据稀疏性与冷启动问题,显著提高推荐系统的推荐质量。

关键词:社会网络;权威;可信度;矩阵分解;推荐

中图分类号: TP391 **文献标志码:** A

Collaborative recommendation algorithm under social network circumstances

LI Hui^{1,2*}, HU Yun^{1,3}, SHI Jun¹

(1. School of Computer Engineering, Huaihai Institute of Technology, Lianyungang Jiangsu 222001, China;

2. School of Information and Electrical Engineering, China University of Mining and Technology, Xuzhou Jiangsu 221008, China;

3. Department of Computer Science and Technology, Nanjing University, Nanjing Jiangsu 210000, China)

Abstract: Concerning data sparsity and malicious behavior of traditional collaborative filtering algorithm, a new social recommendation method combining trust and matrix factorization was proposed in this paper. Firstly, the incredible nodes in the network were founded by computing their prestige value and bias value, and then the weight of their evaluation would be weakened. Finally, the collaborative recommendation was conducted under the social network circumstance by combining the user-item matrix and trust matrix. The experimental results show that the proposed algorithm reduces the importance of not credible node to weaken the negative influence the false or malicious score brings to recommendation system, the data sparsity and malicious behavior problems can be alleviated, and a higher prediction accuracy than that of the traditional collaborative filtering algorithms can be achieved.

Key words: social network; authority; credibility; matrix factorization; recommendation

0 引言

协同过滤算法是通过研究用户的个性化需求来主动向用户推荐最有可能接受的产品。随着 Web 2.0 网站及其应用的迅速发展,电子商务等应用系统中的数据记录都包含了用户之间的交互关系,这些由于人们社会活动而形成的网络统称为社会网络。如何利用社交网络中所提供的丰富的真实世界中人们的社交信息,充分发掘社会网络蕴含的价值以提高网络营销的准确性,为用户提供更精准的推荐,成为社会网络研究的重要方向。

信任网络是由社会网络中所有用户的信任关系所构成的网络^[1]。信任网络是一个有向网络,网络中每个节点代表一个用户,每条边表示用户间的信任关系,边的权重为信任的程度。一些研究已经利用信任网络来提高推荐系统的性能^[2-5]。文献[2]综合用户与朋友的关系进行协同推荐,提出了基于概率的矩阵分解技术来解决评分矩阵的稀疏性问题;文献[3]利用社会网络分析技术分析用户间的关系,将其量化为信任度以填充用户-项矩阵,并将信任度融入到用户相似性计算中;文献[4]使用信任表达和基于信任度量的传播预测用户的偏好。这些信任感知的推荐系统的性能好于使用

传统的协同过滤的系统。但这些研究均未考虑不可信节点对推荐带来的负面影响,因此本文在推荐之前通过发现网络中的不可信节点并弱化其评价权重来降低其对网络产生的负面影响,从而提高了推荐质量。

本文所解决的问题是将社会网络中的可信度分析^[6-10]引入到推荐技术中,并解决推荐系统中普遍存在的数据稀疏和冷启动等问题。对此,本文提出了一种基于可信度的社会网络推荐(Trust-based Social Network Recommendation, TSNR)方法,该方法首先通过计算节点的声望值与偏见值来发现网络中的不可信节点,并通过弱化其评价权重来降低其对网络产生的负面影响;然后,再将用户自身的评分矩阵和朋友的评分相结合,利用矩阵分解技术对用户-项评分矩阵进行分解,以便获得低维的用户和项目的潜在特征空间,从而进行社会网络推荐。实验结果表明在公开数据集上测试本文的推荐算法优于传统的协同推荐算法,特别是在用户的评分项非常稀疏甚至缺失的数据集上。

1 计算节点的偏见值与声望值

本文提出的基于可信度的社会网络推荐方法由两部分构成:首先是通过计算网络节点的偏见值与声望值来发现网络

收稿日期:2013-05-13;修回日期:2013-07-19。 基金项目:江苏省高校自然科学研究项目(13KJB520002);江苏高校优势学科建设项目。

作者简介:李慧(1979-),女,江苏连云港人,讲师,博士研究生,主要研究方向:Web挖掘、信息检索;胡云(1978-),女,江苏连云港人,副教授,博士研究生,主要研究方向:社会网络分析;施珺(1963-),女,安徽桐城人,副教授,硕士,主要研究方向:智能信息化处理。

中的不可信节点,并将其评分权重进行弱化;然后对结合了用户与朋友评分的矩阵进行矩阵分解,从而实现社会网络推荐。

1.1 定义

图是表示社会网络的基本工具,本文利用图来对信任网络进行建模,其中:边的权重表示用户的评价值。一般将社会网络抽象为一张有向图 $G = (V, E)$, V 代表节点的集合, E 表示边的集合,每条边表示个体之间的关系(合作,朋友,敌对等)。其中边 $e_{uv} \in E$ (从节点 u 指向节点 v 的有向边) 的权值表示为 wt_{uv} , 即节点 u 以 wt_{uv} 的信任度指向节点 v 。

令 $d_{out}(u)$ 表示以 u 为起点, u 所指向的所有节点集合, 即 u 的出度集合; $d_{in}(u)$ 表示以 u 为终点, 所有指向 u 的节点集合, 即 u 的入度集合。本文定义了节点的两个属性:

1) 偏见值(bias)。该属性反映了图中节点出边权重的期望值。

2) 声望值(prestige)。该属性反映了来自可信节点的入边权重的期望值。

定义1 偏见值。一个节点的偏见值反映了其信任/不信任其他节点的倾向。因此,一个节点的偏见值可以用该节点对其他节点给出的评分与其应得评分之间的差值来衡量;此差值越大,说明该节点越不可信。用 $b(u)$ 表示节点 u 的偏见值, 用 $p(v)$ 表示节点 v 的声望值, 则节点 u 的偏见值定义如下:

$$b(u) = \frac{1}{2|d_{out}(u)|} \sum_{v \in d_{out}(u)} (wt_{uv} - p(v)) \quad (1)$$

对偏见值进行归一化处理后可以保证其取值范围在 $[-1, 1]$ 区间。如果一个节点的偏见值为0则表示它是可信的。

如果一个节点具有给出一个正面评价的倾向,即对应图中有一条权值为正的出边,则该节点的偏见值就为正值,反之亦然。如果一个节点对其他节点给出了一个值为正的评价值,而这个节点却不应该得到这样的评价值,则该节点的偏见值将会增大。对一个具有高偏见值的节点给出的评价值,其评价的重要程度应当被弱化,可以通过减少该节点所有出边的权值来实现弱化。例如,如果一个具高偏见值(正值)的节点存在一条权值符号为正且权值较大的出边,则该边的权值应当被减少;反之亦然。然而,如果一个节点的偏见值与出边的权值符号是异号时,则对权值大小不进行任何改变。

为了达到这样的目的,引入了一个辅助变量 X_{kv} , 来度量节点 k 的偏见值对节点 v 的每条出边权重的影响力:

$$X_{kv} = \begin{cases} 0, & b(k) \times wt_{kv} \leq 0 \\ |b(k)|, & \text{其他} \end{cases} \quad (2)$$

从上述辅助变量的计算公式可以看出,当节点的偏见值与出边的权值符号为异号时,辅助变量 X_{kv} 的值为0,即对偏见值没有任何影响;否则, X_{kv} 的值为该点偏见值的绝对值。

现在可以利用偏见值的影响(如 X_{kv}) 来重新计算边的权值。新的权重 wt'_{kv} 计算方法如下:

$$wt'_{kv} = wt_{kv} (1 - X_{kv}) \quad (3)$$

从式(3)可以看出,如果节点的偏见值与出边的权值符号是异号时,则新的权重大小保持不变;否则,新的权重将被减少。

一个节点的声望值代表了节点应该得到的真实的可信度,可以利用偏见值来定义声望值。

定义2 声望值。节点的声望值是指来自可信节点入边权重的期望值。声望值的大小取决于入边的质量而不是数量。对于节点的每一条入边,通过调整权值来消减偏见值的影响,

然后再计算所有入边的平均值。节点 v 的声望值定义如下:

$$p(v) = \frac{1}{|d_{in}(v)|} \sum_{k \in d_{in}(v)} wt'_{kv} \quad (4)$$

1.2 偏见值与声望值的计算

在本节中给出计算网络中所有节点的偏见值与声望值的具体算法。通过式(1)和式(4)可以看出,偏见值和声望值其实是相互迭代的。节点的偏见值取决于其邻居节点的声望值,而其声望值又取决于其邻居节点的偏见值,如此迭代下去。因此,要想求得最终解,本文采用不动点迭代方法进行求解。

将 $b^t(u)$ 和 $p^t(u)$ 分别定义为节点 u 在第 t 次迭代时的偏见值与声望值,利用节点在第 t 次迭代时所获得的结果去计算第 $t+1$ 次迭代的结果。从偏见值与声望值的初始值开始,计算所有节点在下一迭代后的声望值,然后利用这些声望值去重新估算其偏见值。因此, $p^{t+1}(u)$ 取决于 $b^t(\cdot)$, 其值依次利用 $p^t(\cdot)$ 可以得到求解。式(1)和式(4)可以被重新定义如下:

$$p^{t+1}(v) = \frac{1}{|d_{in}(v)|} \sum_{k \in d_{in}(v)} (wt_{kv} (1 - X_{kv}^t)) \quad (5)$$

$$b^{t+1}(u) = \frac{1}{2|d_{out}(u)|} \sum_{v \in d_{out}(u)} (wt_{uv} - p^t(v)) \quad (6)$$

经过式(5)~(6)计算,网络节点的偏见值与声望值已经求出,如果节点的偏见值越大,说明其给出的评价是不可信的,通过式(3)可以弱化其评分的重要性,在此基础上再进行推荐,可以保证推荐的可信度与推荐质量。

2 基于可信度的社会网络推荐

传统的协同推荐技术,如协同过滤,仅仅是利用用户-项评分矩阵进行推荐,而忽略了用户间的社会信任关系,但其实人们往往是最容易接受来自其信任的朋友推荐。因此,本章介绍一种利用矩阵分解技术实现基于可信度的推荐算法。

2.1 问题定义

在推荐系统中,设 $\{u_1, \dots, u_N\}$ 代表用户集合, $\{v_1, \dots, v_M\}$ 代表项目集合, $\mathbf{R} = [R_{u,v}]_{N \times M}$ 表示用户对项目的评分矩阵,其中 $R_{u,v}$ 表示用户 u 对项目 v 的评分。 $R_{u,v}$ 可以为任意实数,但在社交网络中用户的评分一般都是采用五分制来表达自己的喜好程度。在本文中,不失一般性,也将用户的评分映射到 $[0, 1]$ 区间。在社会网络中,每一个用户 u 都会有邻居集合 N_u , 用 $wt_{u,v}$ 表示节点 u 对节点 v 的社会信任度,其取值范围在 $[-1, 1]$ 区间。值为 -1 时表示完成不信任,值为 1 时表示完成信任。通过 1.2 节的分析可知,对一个具有高偏见值的节点给出的评价值,其评价的重要程度应当被弱化。因此,利用式(3)所求得的修正后的权值 wt'_{kv} 构建信任度矩阵 $\mathbf{T} = [T_{u,v}]_{N \times N}$ 。

基于可信度的推荐目标可以描述为:利用用户的评分矩阵 \mathbf{R} 和信任度矩阵 \mathbf{T} 来预测用户 u 对项目 v 的未知评分。

本文利用矩阵分解技术^[10] 来分别获得低维的用户潜在特征空间和项目潜在特征空间来预测用户评分,从而进行社会网络推荐。令 $\mathbf{U} \in \mathbf{R}^{K \times N}$ 表示用户特征矩阵, $\mathbf{V} \in \mathbf{R}^{K \times M}$ 表示项目特征矩阵, k 维列向量分别表示用户 u 和项目 v 的潜在特征空间。矩阵分解的目标就是将一个稀疏的评分矩阵分解为两个矩阵:一个表示用户的特征,一个表示项目的特征,将两个矩阵中各取一行和一列向量做内积得到预测结果。

2.2 基于可信度的推荐模型

传统的推荐方法,如协同过滤方法,仅仅利用用户-项评

分矩阵进行推荐,而忽略了用户之间的社会信任关系。随着在线社会网络的发展,将社会网络引入到推荐系统中已经变得越来越重要了。本节将介绍在矩阵分解技术中引入信任度矩阵进行社会网络推荐的具体方法。

由于社会关系网络的存在,用户 u 的行为与喜好经常受到其邻居节点 N_u 的影响,用户更愿意接受来自其信任的好友推荐。换句话说,用户 u 的特征向量依赖于其所有邻居节点 $v \in N_u$ 。因此可以将这种影响表示为:

$$\bar{\mathbf{R}}_{ik} = \sum_{j \in N_u} wt'_{i,j} \mathbf{R}_{jk} \quad (7)$$

其中: $\bar{\mathbf{R}}_{ik}$ 表示用户 u_i 对项目 v_j 的预测评分; \mathbf{R}_{jk} 表示用户 u_j 对项目 v_k 已给出的评分; wt'_{kv} 是利用式(3)求得的修改后的权重。则用户 u 对所有项目的预测评分可表示为:

$$\begin{bmatrix} \bar{\mathbf{R}}_{i,1} \\ \bar{\mathbf{R}}_{i,2} \\ \vdots \\ \bar{\mathbf{R}}_{i,m} \end{bmatrix} = \begin{bmatrix} R_{1,1} & R_{2,1} & \cdots & R_{n,1} \\ R_{2,1} & R_{2,2} & \cdots & R_{n,2} \\ \vdots & \vdots & \ddots & \vdots \\ R_{1,k} & R_{2,k} & \cdots & R_{n,m} \end{bmatrix} \begin{bmatrix} wt'_{i,1} \\ wt'_{i,2} \\ \vdots \\ wt'_{i,n} \end{bmatrix} \quad (8)$$

本文利用修正后的权重 wt'_{kv} 构建信任度矩阵 \mathbf{T} , 因此对于所有用户的预测评分可表示为:

$$\bar{\mathbf{R}} = \mathbf{TR} \quad (9)$$

由文献[11]可以利用矩阵分解技术对用户-项评分矩阵进行分解,从而获得用户和项目的特征向量。用户评分的条件概率表示如下:

$$p(\mathbf{R} | \mathbf{U}, \mathbf{V}, \sigma_R^2) = \prod_{i=1}^n \prod_{j=1}^m [N(\mathbf{R}_{ij} | g(\mathbf{U}_i^T \mathbf{V}_j), \sigma_R^2)]^{I_{ij}^R} \quad (10)$$

其中: $N(x | \mu, \sigma^2)$ 表示随机变量 x 服从一个数学期望为 μ , 标准方差为 σ^2 的高斯分布; I_{ij}^R 为一个指示函数, 如果用户 u_i 对项目 v_j 有评分, 则其值为 1, 否则为 0; 对数函数 $g(x) = 1/(1 + \exp(-x))$ 。

从社会信任网络出发, 将信任度矩阵 \mathbf{T} 引入到式(10)中, 可得:

$$p(\mathbf{R} | \mathbf{T}, \mathbf{U}, \mathbf{V}, \sigma_R^2) = \prod_{i=1}^n \prod_{j=1}^m [N(\mathbf{R}_{ij} | g(\sum_{k \in N_u} w_{ik} \mathbf{U}_k^T \mathbf{V}_j), \sigma_R^2)]^{I_{ij}^R} \quad (11)$$

作为一种推理方法, 贝叶斯推理从概率论中的贝叶斯定理扩充而来^[11]。贝叶斯定理断定: 已知一个事件集 $B_i (i = 1, 2, \dots, k)$ 中第一个 B_i 的概率 $P(B_i)$, 又知在 B_i 已发生的条件下事件 A 的条件概率 $P(A/B_i)$, 就可得出在给定 A 已发生的条件下任何 B_i 的条件概率 $P(B_i/A)$, 即:

$$P(B_i/A) = P(B_i)P(A/B_i) / (P(B_1)P(A/B_1) + P(B_2)P(A/B_2) + \cdots + P(B_n)P(A/B_n))$$

对式(11)应用贝叶斯推理可得:

$$p(\mathbf{U}, \mathbf{V} | \mathbf{R}, \mathbf{T}, \sigma_w^2, \sigma_U^2, \sigma_V^2) \propto p(\mathbf{R} | \mathbf{T}, \mathbf{U}, \mathbf{V}, \sigma_w^2) p(\mathbf{U} | \mathbf{T}, \sigma_U^2) p(\mathbf{V} | \mathbf{T}, \sigma_V^2) \quad (12)$$

式(12)中, 假设 \mathbf{T} 与低维矩阵 \mathbf{U} 和 \mathbf{V} 是相互独立的, 则式(12)可表示为:

$$p(\mathbf{U}, \mathbf{V} | \mathbf{R}, \mathbf{T}, \sigma_w^2, \sigma_U^2, \sigma_V^2) \propto p(\mathbf{R} | \mathbf{w}, \mathbf{U}, \mathbf{V}, \sigma_w^2) p(\mathbf{U} | \sigma_U^2) p(\mathbf{V} | \sigma_V^2) = \prod_{i=1}^n \prod_{j=1}^m [N(\mathbf{R}_{ij} | g(\sum_{k \in N_u} w_{ik} \mathbf{U}_k^T \mathbf{V}_j), \sigma_w^2)]^{I_{ij}^R} \times$$

$$\prod_{i=1}^n N(\mathbf{U}_i | \mathbf{0}, \sigma_U^2 \mathbf{I}) \times \prod_{j=1}^m N(\mathbf{V}_j | \mathbf{0}, \sigma_V^2 \mathbf{I}) \quad (13)$$

3 实验结果

本章将在现实的基于信任度的社交网络上进行实验, 对基于可信度的推荐与传统的协同推荐方法进行比较, 验证本文提出的 TSNR 算法的有效性。

3.1 数据准备与评价指标

本文使用了两个现实的数据集: Epinions 和 Slashdot 来完成验证实验。数据集可以在斯坦福大型网络数据集 (<http://snap.stanford.edu>) 上获取。

Epinions 是一个拥有大型用户的产品评论网站。用户在网站中发表产品评论, 然后对所有用户关于同一产品的打分最终统计出哪些评论是最有权威性的。数据收集了自 1999 年开始至 2003 年 12 月之间的所有数据。网络中总共包含了 119 217 个节点和 841 000 条边。选取了 51 670 个用户及其对 83 509 个项目的评分数据。用户-项评分矩阵的密度小于 0.015%。

Slashdot 是一个与技术相关的新闻站点。自 2002 年起, 该网站引入了 Slashdot Zoo——允许用户将其他人标记为自己的“朋友”或是“敌人”。这种标记关系与 Epinions 网站的评论在语义上是相似的: 朋友关系意味着一个用户喜欢另外一个用户的评论, 而敌对关系意味着一个用户对另外一个用户的评论不感兴趣。本文抓取了该网站上自 2009 年开始的数据, 包括 82 144 个用户与 549 202 条边, 其中 77.4% 是正数。70 284 个节点至少存在至少一条带符号的入边, 并且有 2 188 个节点有入边和出边。

实验使用平均绝对误差 (Mean Absolute Error, MAE) 和均方根误差 (Root Mean Square Error, RMSE) 作为衡量传统推荐系统与基于信任度的推荐系统性能的评价指标。MAE 是所有单个观测值与算术平均值的偏差的绝对值, 其定义如下:

$$MAE = \frac{\sum_{i,j} |r_{i,j} - \bar{r}_{i,j}|}{N}$$

其中: $r_{i,j}$ 表示用户 i 对项目 j 的实际评分, $\bar{r}_{i,j}$ 表示应用推荐模型预测用户对项目的预测得分, N 为观测次数。

RMSE 表示观测值与真值偏差的平方和观测次数 n 比值的平方根的平均, 其定义如下:

$$RMSE = \sqrt{\frac{\sum_{i,j} (r_{i,j} - \bar{r}_{i,j})^2}{N}}$$

3.2 偏见值与声望值分布验证实验

第一个实验是对节点的偏见值与声望值分布的验证实验。本文将节点的声望值分布与其入度平均值进行了对比。节点的入度平均值表示节点所有入边权值的平均值。图 1 给出了在 Slashdot 数据集上节点的入度平均值的柱形图。从图 1 可以看出, 在该数据集上, 入度平均值为 1 的节点数量非常多, 其次是入度平均值为 -1 的节点数量。这主要是因为数据集中大概有 80% 的边拥有正的权值。

图 2 给出了节点声望值的分布图, 从图中可以看出, 由于去除了偏见值的影响, 节点声望值的分布比入度平均值的分布更平滑。由此可以验证本文提出的偏见节点发现方法的有效性。




图1 Slashdot数据集上入度平均值分布




图2 Slashdot数据集上节点声望值分布

3.3 与传统推荐系统的对比实验

为了验证本文提出的 TSNR 算法在推荐性能上的改进, 现将其与下列推荐方法进行了对比实验。

1) SSR-CF。该方法是由罗辛等^[12]提出的, 利用相似度支持度来对传统协同过滤的最近邻选择进行改进。

2) PMF。该方法是由 Salakhutdinov 等^[10]提出的。PMF 方法仅仅利用用户-项评分矩阵进行协同推荐, 也是使用基于概率的矩阵分解技术。

3) Trust。该方法是基于信任网络的协同推荐方法^[2]。与本文不同, 本文通过降低网络中不可信节点的评分重要性, 从而消减了不可信节点对推荐系统带来的负面影响, 因此可以认为是基于信任网络的推荐系统的优化与改良。

推荐系统最主要的挑战就是数据稀疏性问题, 即在用户的评分项非常稀疏的数据集上很难进行准确的推荐。因此, 为了比较本文算法与其他推荐算法的性能, 先将训练集中的用户按参与评分的人数多少进行分组, 然后评估在不同用户分组下系统预测的准确度。用户按参评人数共分为 6 组: “1~10”、“11~20”、“21~40”、“41~80”、“81~160”和“>160”, 实验结果如图 3~4 所示。

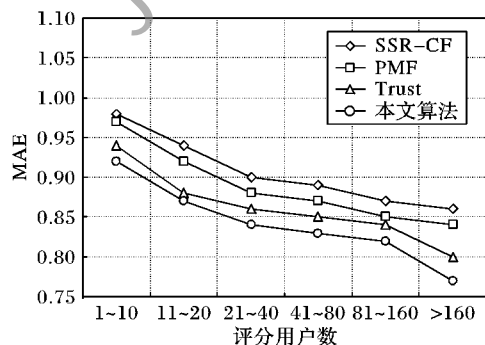


图3 MAE 对比实验结果

从图 3~4 中可知, 本文提出的算法在平均绝对误差与均方根误差等指标上均优于 Trust、PMF 算法, 特别是在用户评分项极其稀疏的数据集上。

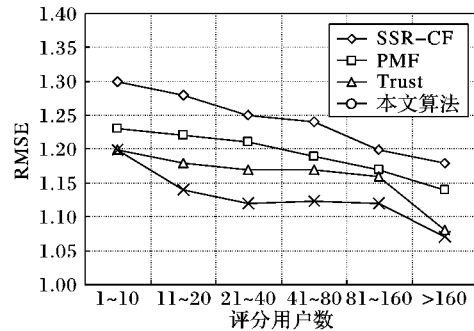


图4 RMSE 对比实验结果

4 结语

在基于可信网络中的诸多应用中, 对网络节点的可信度进行评估是一项关键技术。针对在社交网络中用户更愿意接受来自朋友的推荐这一社会现象, 本文提出一种融合信任度、利用矩阵分解技术实现社会网络推荐的方法, 该方法是弱化网络中的不可信节点所给出的评分重要性, 从而消减虚假评分或恶意评分给推荐系统带来的负面影响, 保证用户收到的是真正可信的推荐, 从而提高了推荐系统的准确度。

参考文献:

- [1] MASSA P, BHATACHARJEE B. Using trust in recommender systems: an experimental analysis [C]// Proceedings of the 2nd Conference on Trust Management. Berlin: Springer, 2005: 221-235.
- [2] MA H, YANG H X, LYU M R, et al. SoRec: social recommendation using probabilistic matrix factorization [C]// Proceedings of the 17th ACM International Conference on Information and Knowledge Management. New York: ACM Press, 2008: 931-941.
- [3] 冯勇, 李军平, 徐红艳, 等. 基于社会网络分析的协同推荐方法改进[J]. 计算机应用, 2013, 33(3): 841-844.
- [4] MASSA P, AVESANI P. Trust-aware recommender systems [C]// Proceedings of the 2007 ACM Conference on Recommender Systems. New York: ACM Press, 2007: 17-24.
- [5] 俞琰, 邱广华. 用户兴趣变化感知的重启随机游走推荐算法研究[J]. 现代图书情报技术, 2012(4): 48-53.
- [6] NOEL J, SANNER S, TRAN K N, et al. New objective functions for social collaborative filtering [C]// Proceedings of the 21st International Conference on World Wide Web. New York: ACM Press, 2012: 859-868.
- [7] LESKOVEC J, HUTTENLOCHER D, KLEINBERG J. Signed networks in social media [C]// Proceedings of the SIGCHI Conference on Human Factors in Computing Systems. New York: ACM Press, 2010: 1361-1370.
- [8] KIM Y, SHIM K. TWITTOBI: a recommendation system for twitter using probabilistic modeling [C]// Proceedings of the 11th IEEE International Conference on Data Mining. Piscataway: IEEE Press, 2011: 340-349.
- [9] 王刚, 桂小林. 社交网络中交易节点的选取及其信任关系计算方法[J]. 计算机学报, 2013, 36(2): 368-383.
- [10] SALAKHUTDINOV R, MNH A. Probabilistic matrix factorization [C]// Proceedings of Advances in Neural Information Processing Systems. New York: ACM Press, 2008: 1257-2164.
- [11] PAISLEY J, BLEI D, JORDAN M I. Variational bayesian inference with stochastic search [C]// Proceedings of the 29th International Conference on Machine Learning. Piscataway: IEEE Press, 2012: 233-245.
- [12] 罗辛, 欧阳元新, 熊璋, 等. 通过相似度支持度优化基于 K 近邻的协同过滤算法[J]. 计算机学报, 2010, 33(8): 1437-1445.