

基于信任的协同过滤算法^①

吴 慧, 卞艺杰, 赵 喆, 马瑞敏

(河海大学 商学院, 南京 211100)

摘 要: 针对 O2O 电子商务平台推荐准确率低的问题, 本文从用户活跃度和用户权威度两个方面计算用户全局信任度, 引入用户之间的信任关系对传统的协同过滤算法进行改进, 设定信任度阈值来确定邻居用户的范围, 在此基础上结合信任度和相似度两个因素确定邻居用户, 以信任度和相似度结合的混合值作为推荐权重, 实验证明, 该算法与传统的协同过滤推荐算法和基于信任关系的推荐算法相比有更好的效果。

关键词: 信任; 协同过滤; 算法

Collaborative Filtering Algorithm Based on Trust

WU Hui, BIAN Yi-Jie, ZHAO Zhe, MA Rui-Min

(Business School, Hohai University, Nanjing 211100, China)

Abstract: According to the problem of the low precision rate of resources recommended in O2O E-Commerce platform, the paper calculates user's global-trust in the system from two aspects of user activity and user authority. On this basis, it improves the traditional collaborative filtering algorithm with the introduction of trust relationship between users. It sets confidence threshold to determine the scope of neighboring users. On this basis, combined with trust and similarity to determine the neighbor users, this work puts their combined mixed Numerical as recommended weights. The experimental results can prove the validity and superiority of the proposed algorithm.

Key words: trust; collaborative filtering; algorithm

传统的协同过滤算法根据用户——项目评分数据计算用户之间的相似度, 把用户之间的相似度作为推荐权重。而在日常生活中, 人们在接受他人(称为推荐人)的推荐时, 首先会考虑推荐人与自己的兴趣爱好是否相同, 该推荐人以前是否推荐过令自己满意的商品; 如果是一个陌生人的推荐, 人们会考虑推荐人整体的信誉情况, 决定是否接受其推荐的商品。传统的协同过滤算法并没有考虑不同人之间的信任度问题。

目前, 已有不少学者将信任概念引入电子商务推荐系统中^{[1]-[8]}, 从不同程度上改进了推荐准确性、数据稀疏度等问题。文献^[9]通过结合社会网络的理论知识, 对电子商务中信任网络的构造方法和优化算法进行了研究。文献^[10]通过对全局信任度和局部信任度进行研究, 提出了基于信任的协同过滤算法。文献^[11]将信任

度和相似度结合, 改进了相似度计算方法, 提高了推荐的准确率, 其不足是对全局信任度影响的因素考虑得过于简单。

本文提出基于信任度的协同过滤算法, 该算法把信任作为影响推荐的一个重要因素, 不仅考虑了一个用户对邻居用户的信任度, 也考虑了用户在整个系统中的可信度, 并且从用户活跃度和用户权威两个方面来计算用户全局信任度的一种新的思路。

1 协同过滤算法中的信任

Ziegler^[12]等人通过对用户相似度和用户之间的信任关系进行研究, 得出如下结论: 用户之间的信任度和用户相似度具有较强的相关性, 并且满足如下不等式:

^① 收稿时间:2013-11-12;收到修改稿时间:2013-12-06

$$\forall a, b \in U, \frac{\sum_{b \in trust(a)} sim(a, b)}{|trust(a)|} \gg \frac{\sum_{c \in (U - trust(a))} sim(a, c)}{|U - trust(a)|} \quad (1)$$

其中, U 代表系统中所有用户集合, trust(a)代表和用户 a 具有直接信任关系的用户集合, sim(a,b)表示用户 a 和用户 b 之间的相似度. 不等式左边表示用户 a 与其信任用户的相似度平均值, 右侧表示用户 a 与系统中其他用户之间的相似度平均值. 公式 1 表明, 具有信任关系的用户之间的平均相似度要远大于没有信任关系的用户之间的平均相似度.

根据公式(1), 利用相似度和信任度之间的关系, 对具有信任关系的用户设定信任度阈值, 大于这一阈值的用户之间具有相似性的可能性较大. 在此基础上计算用户之间的混合相似度, 提高搜索效率, 在一定程度上缓解数据稀疏问题, 提高系统推荐的精确度.

将信任引入传统的协同过滤算法中, 信任可分为局部信任度和全局信任度. 局部信任度是指在系统中, 目标用户对邻居用户的信任度. 全局信任度是指用户在整个系统中的可信度. 在同一系统中, 每个用户之间的间接信任度是不同的, 每个用户只有唯一的整体信任度. 信任具有以下性质: 主观性、动态性、弱传递性、可度量性、信任的实体复杂性. 信任是非对称的, a 信任 b, b 不一定信任 a.

2 基于信任网络的协同过滤算法(TNB-CF)

Step1:建立用户评分矩阵,将用户对项目的显性、隐性评分、评价行为等,根据一定的规则转换成数值评分,形成用户项目评分矩阵.

Step2: 采用 Pearson 相关系数公式^[9]来计算用户之间的相似度.

$$sim(m, n) = \frac{\sum_{c \in I_{m,n}} (r_{m,c} - \bar{r}_m)(r_{n,c} - \bar{r}_n)}{\sqrt{\sum_{c \in I_{m,n}} (r_{m,c} - \bar{r}_m)^2} \sqrt{\sum_{c \in I_{m,n}} (r_{n,c} - \bar{r}_n)^2}} \quad (2)$$

$r_{m,c}, r_{n,c}$ 表示用户 m, 用户 n 对项目 c 的评分; \bar{r}_m, \bar{r}_n 表示用户 m, 用户 n 对所有项目评分的平均值;

Step3:计算目标用户对其他用户的信任度.

1)直接信任是指在推荐系统中, 用户之间通过直接信息交互(如评价、推荐等)建立起来的信任关系.

假定用户 a 是用户 b 一个单独的邻居用户, 用户 a 对用户 b 进行推荐, 在用户 a 和用户 b 的共同评分项

目集 $TotalSet(u_a, u_b)$ 中, 用户 a 对用户 b 正确推荐个数 $CorrectSet(u_a, u_b, i)$ 所占的比例, 可以表示为用户 b 对用户 a 的直接信任度 $T_1(u_b, u_a)$, 如公式 3 所示.

$$T_1(u_b, u_a) = \frac{\sum_{i \in TotalSet(u_a, u_b)} correct(u_a, u_b, i)}{TotalSet(u_a, u_b)} \quad (3)$$

$CorrectSet(u_a, u_b, i)$ 是指用户 a 将项目 i 推荐给用户 b 时, 用户 b 认为这次推荐是正确的. 并且有

$$CorrectSet(u_a, u_b) = \sum_{i \in TotalSet(u_a, u_b)} Correct(u_a, u_b, i) \quad (4)$$

2) 计算目标用户对邻居用户的信任度时,不仅要考虑目标用户与邻居用户的直接信任度,还应考虑邻居用户在整个系统里的可信度,即全局信任值. 用户活跃度和用户权威度是全局信任度的两个决定因素.

①用户活跃度(Activity)

根据用户在系统中的评分数量来判断用户在系统中的活跃度, 用户在系统中的活跃度跟用户的评分数量成正比, 评分数量越多, 用户活跃度越高.

定义用户活跃度权重因子 w 来衡量用户在系统中的活跃程度, w 的计算公式为:

$$w = \begin{cases} 1, & \text{当 } q \geq Q \text{ 时;} \\ \frac{q}{Q}, & \text{当 } 0 < q < Q \text{ 时;} \\ 0, & \text{当 } 0 \leq q \ll Q \text{ 时;} \end{cases} \quad (5)$$

其中, $w \in [0,1]$. w 的含义为: 当用户对系统中项目的评分数量 q 超过给定的阈值 Q 时, 认为用户非常可信; 时, 即用户的评分数量 q 远小于 $\frac{Q+q}{Q} = 1$ 给定阈值 Q, 当用户还没有对系统项目进行评分时, 用户活跃度权重因子 $w = 0$; 当用户评分数量足够多但又不到给定阈值 Q 时, 用户活跃度权重因子为该用户的评分数量与阈值 Q 的比例. 阈值 Q 根据系统的实际情况来定, 一般情况下, $Q \leq Q_{max}$, Q_{max} 为系统中最活跃用户(即评分数量最多的用户)的评分数量之和.

②用户权威度(Authority)

用户权威度主要体现在用户的评分质量上. 用户的评分质量体现用户提供可靠信息的能力, 即用户对某一项目的评分对其他用户的价值大小. 如果某一评分对其他用户的价值大, 即该用户的评分质量高, 则认为该用户在系统中有较高的权威度;反之, 认为用户在系统中的权威度不高. 根据用户在系统中所有评分

的评分质量均值判断该用户在系统中的权威度. 计算用户对单个项目评分的评分质量, 如公式 6 所示:

$$T_e(r_a^i) = 1 - \frac{|r_a^i - \bar{R}_{\text{arg}}^i|}{r_{\text{max}}^i} \quad (6)$$

$T_e(r_a^i)$ 来表示用户评分质量值, r_a^i 表示用户 **a** 对项目 **i** 的实际评分, r_{max}^i 是项目 **i** 在系统中所获得的最大评分, \bar{R}_{arg}^i 为项目 **i** 的评分平均值, $\bar{R}_{\text{arg}}^i = \frac{1}{N} \sum_{a=1}^N r_a^i$, \bar{R}_{arg}^i 也可以不计算用户 **a** 对项目 **i** 的评分值, 用 $\bar{R}_{\text{arg}1}^i = \frac{1}{N-1} ((\sum_{a=1}^N r_a^i) - r_a^i)$ 来代替, 当 N 很大时, $\bar{R}_{\text{arg}1}^i = \bar{R}_{\text{arg}}^i$.

通过对用户所有评分的评分质量值求平均值, 计算出用户 **a** 在系统中的权威度 $T_e(a)$, 如公式 7 所示

$$T_e(a) = \frac{1}{q} \times \sum_{i=1}^q T_e(r_a^i) = \frac{1}{q} \times \sum_{i=1}^q (1 - \frac{|r_a^i - \bar{R}_{\text{arg}}^i|}{r_{\text{max}}^i}) \quad (7)$$

③全局信任度的计算

用户活跃度权重因子 w 体现了用户在系统中的活跃程度, 是计算用户全局信任度的决定性因素. 如果用户在系统中评分数量很少, 即使该用户对某一项目的评分质量很高, 也认为其全局信任度不高. 根据用户活跃度权重因子 w 和用户权威度 $T_e(a)$, 可以计算出用户 **a** 的全局信任度 $T_2(a)$, 如公式 8 所示.

$$T_2(a) = w \times T_e(a) = w \times \frac{1}{q} \times \sum_{i=1}^q (1 - \frac{|r_a^i - \bar{R}_{\text{arg}}^i|}{r_{\text{max}}^i}) \quad (8)$$

将用户活跃度权重因子 w 带入, 则用户的全局信任度 $T_2(a)$ 为:

$$T_2(a) = \begin{cases} \frac{1}{q} \times \sum_{i=1}^q (1 - \frac{|r_a^i - \bar{R}_{\text{arg}}^i|}{r_{\text{max}}^i}) & \text{当 } q \geq Q \text{ 时;} \\ \frac{1}{Q} \times \sum_{i=1}^q (1 - \frac{|r_a^i - \bar{R}_{\text{arg}}^i|}{r_{\text{max}}^i}) & \text{当 } 0 < q < Q \text{ 时} \\ 0 & \text{当 } 0 \leq q \ll Q \end{cases} \quad (9)$$

(4)在系统中计算用户 **b** 对用户 **a** 的信任度时, 不

仅要考虑用户 **b** 对用户 **a** 的局部信任度, 同时也要考虑用户 **a** 在系统中的全局信任度, 其权重也有所不同. 根据局部信任度 $T_1(u_b, u_a)$ 和全局信任度 $T_2(a)$, 可以计算出用户 **b** 对用户 **a** 的信任度 $T_{b \rightarrow a}(a, b)$, 公式 10 所示.

$$T_{b \rightarrow a}(a, b) = \lambda T_1(u_b, u_a) + (1 - \lambda) T_2(a) = \lambda \frac{\sum_{i \in \text{TotalSet}(u_a, u_b)} \text{correct}(u_a, u_b, i)}{\text{TotalSet}(u_a, u_b)} + (1 - \lambda) \begin{cases} \frac{1}{q} \times \sum_{i=1}^q (1 - \frac{|r_a^i - \bar{R}_{\text{arg}}^i|}{r_{\text{max}}^i}) & \text{当 } q \geq Q \text{ 时;} \\ \frac{1}{Q} \times \sum_{i=1}^q (1 - \frac{|r_a^i - \bar{R}_{\text{arg}}^i|}{r_{\text{max}}^i}) & \text{当 } 0 < q < Q \text{ 时} \\ 0 & \text{当 } 0 \leq q \ll Q \end{cases} \quad (10)$$

λ 表示局部信任度的权重值, $\lambda \in [0,1]$. λ 取值可由专家给出然后进行调试, 也可由系统的历史数据调试得出, 其他变量的含义同公式 7 和公式 9 相同.

分析公式 10, 可看出该公式满足信任的动态性和非对称性的特点. 随着用户 **a** 在系统中的评分行为不断变化, 用户的活跃度和权威度也随之改变, 这满足信任的动态性的特点. 另一方面, 在计算两个用户之间的信任度时, 考虑了邻居用户的全局信任度, 即公式 10 中的 $(1 - \lambda) T_2(a)$, 从而出现用户 **b** 对用户 **a** 的信任度并不等于用户 **a** 对用户 **b** 的信任度的情况, 满足了信任的非对称性的特点: $T(a, b) \neq T(b, a)$.

Step4: 确定信任度阈值 T_c , 构建用户信任度矩阵 $T_{M \times M}$. 根据 $\text{Trust}_{i,j} \geq T_c$, 取前 M 个信任度最高的邻居用户, 组成用户信任度矩阵 $T_{M \times M}$.

$$T_{M \times M} = T(jk)_{M \times M} = \begin{pmatrix} T_{11} & \dots & T_{1m} \\ \dots & \dots & \dots \\ T_{M1} & \dots & T_{MM} \end{pmatrix} \quad (11)$$

其中, 元素 T_{jk} 表示用户 **j** 对用户 **k** 的信任度. 根据信任的不对称性, $T_{jk} \neq T_{kj}$; $T_{jj} = 1$, 表示用户对自己是完全信任的.

Step5: 根据 Step4 中确定的邻居用户的范围, 结合 Step2 计算出的相似度, 构建用户相似度矩阵 $S_{M \times M}$. 其中, 每个元素 S_{jk} 表示用户 **j** 和用户 **k** 之间的相似度值 $\text{sim}(j, k)$. 由于评分数据比较稀疏, 致使部分用户之间的相似度不能计算, 相似度矩阵 $S_{M \times M}$ 比较稀疏.

$$S_{M \times M} = S(jk)_{M \times M} = \begin{pmatrix} S_{11} & \dots & S_{1m} \\ \dots & \dots & \dots \\ S_{M1} & \dots & S_{MM} \end{pmatrix} \quad (12)$$

Step6: 合并矩阵. 用户信任度矩阵 $T_{M \times M}$ 和用户相

似度矩阵 $S_{M \times M}$ 都是单独存在, 同时两个矩阵又具有一定的稀疏性, 因此将用户信任度矩阵 $T_{M \times M}$ 和用户相似度矩阵 $S_{M \times M}$ 进行合并, 得到混合矩阵 $ST_{M \times M}$, 并将混合矩阵 $ST_{M \times M}$ 中的元素 ST_{ij} (称为混合相似度) 作为最终推荐的权重. 如公式 13 所示.

$$ST_{j \rightarrow k}(j, k) = \begin{cases} \frac{2 \times \text{sim}(j, k) \times T_{j \rightarrow k}(j, k)}{\text{sim}(j, k) + T_{j \rightarrow k}(j, k)}, & \text{if } \text{sim}(i, j) > 0 \text{ and } T_{j \rightarrow k}(j, k) > 0 \\ T_{j \rightarrow k}(j, k), & \text{if } \text{sim}(i, j) = 0 \text{ and } T_{j \rightarrow k}(j, k) > 0 \\ 0 & \text{if } T_{j \rightarrow k}(j, k) = 0 \end{cases} \quad (13)$$

通过合并用户信任度矩阵 $T_{M \times M}$ 和用户相似度矩阵 $S_{M \times M}$, 一方面可以使合并后的矩阵相对来说比较稠密, 能够为目标用户匹配到更多的邻居用户; 另一方面, 合并后的矩阵不仅考虑了用户之间的相似度, 也将用户之间的信任度计算在内, 能够提高系统推荐的精确度, 提高用户对推荐系统的满意度.

Step7: 选择最近邻居. 混合矩阵 $ST_{M \times M}$ 与目标用户混合相似度最高的前 L 个用户作为最近邻居集合.

Step8: 产生推荐. 根据已经确定的邻居用户及其评分记录, 可以计算出目标用户对预测项目的评分值, 也即推荐值. 传统的基于用户的协同过滤算法将用户相似度作为推荐值的权重, 本文将原来的用户相似度改为混合相似度, 改进后的公式如 14 所示.

$$P_{u,i} = \frac{\sum_{k=1}^l (R_k(i) - \bar{R}_k) \times ST_{u \rightarrow k}(u, k)}{\sum_{k=1}^m (|ST_{u \rightarrow k}(u, k)|)} \quad (14)$$

其中, \bar{R}_u 表示用户 u 的评分平均值, l 为邻居用户个数, $R_k(i)$ 为用户 k 对项目 i 的评分值, \bar{R}_k 为用户 k 的评分平均值, $ST_{u \rightarrow k}(u, k)$ 表示用户 k 对用户 u 的推荐权重, $P_{u,i}$ 则是用户 u 对项目 i 的预测评分值. 最后, 选择预测评分值最高的前 N 个用户形成对目标用户 u 的 Top-N 推荐列表.

3 实证分析

3.1 数据集的筛选和评价指标

实验选取 MovieLens 数据集, 用户评分数据收集了 943 个用户对 1682 部电影的 100000 条评分记录, 用 java 编程实现上述算法并测试程序. 数据稀疏度通过公式 15 计算, 得到该数据集的稀疏度为 93.70%.

$$\text{稀疏度} = \frac{\text{用户数} \times \text{资源数} - \text{数据集中所有已评分数目}}{\text{用户数} \times \text{资源数}} = \frac{943 \times 1682 - 100000}{942 \times 1682} \quad (15)$$

实验将随机选择数据集集中的 80% 作为训练集, 20% 作为测试集. 本文采用广泛使用的平均绝对误差 MAE (Mean Absolute Error) 对预测精准度进行分析, 即计算测试集中的项目预测评分与项目实际评分之间的差值绝对值的平均值. 假设 P_i 是预测值, Q_i 是实际评分, 共有 N 个预测项目, 平均绝对误差的计算如公式 16 所示:

$$MAE = \frac{\sum_{i=1}^N |p_i - q_i|}{N} \quad (16)$$

3.2 实验过程和结果分析

实验一: 确定局部信任度的权重值 λ

实验时, 分别测试邻居用户数量 K 为 10、20、30、40、60 时, 赋予 λ 不同的值 ($\lambda \in [0, 1]$), 观察随着 λ 的变化, 平均绝对误差 MAE 的变化情况, 进而确定 λ .




图 1 MAE 值随 λ 的变化曲线

在图 1 中, 横坐标表示局部信任度权重值 λ , 纵坐标表示平均绝对误差 MAE. 在所选数据集条件下, 邻居数量仅为 10 时, MAE 值较大, 主要是因为邻居个数太少, 预测结果不准确, 推荐效果不理想. 随着邻居用户数量的不断增加, 平均绝对误差 MAE 逐渐降低. λ 取值在 0 到 0.3 时, MAE 值不断降低, 并且在 $\lambda = 0.3$ 时, MAE 值达到最低点, 推荐结果达到最优; 其后随着 λ 值的变大, MAE 值有增大趋势, 并逐渐达到稳定. 从图 1 可知, 同时引入局部信任度和全局信任度能够提高推荐准确度. 以最近邻居个数为 60 为例, 当 λ 取值为 0 时, 代表在推荐时没有考虑用户之间的局部信任度, MAE 值为 0.7638; 当 λ 取值为 1 时, 即在推荐时没有考虑用户的全局信任度, MAE 值为 0.7547. 两种情况下, MAE 值都没有达到最低.

实验二: TNB-CF 算法与传统的 CF 算法、基于改进信任度的协同过滤算法^[11]对比

根据实验一得到 $\lambda = 0.3$, 对本文提出的 TNB-CF 与传统的 CF 算法、基于改进信任度的协同过滤算法进行对比. 本文与文献^[11]中提出的基于改进信任度的

协同过滤算法采用相同的数据集,均分割为训练集 80%和测试集 20%,并采用相同的评价指标 MAE,测试邻居用户个数 K 从 10 到 100 逐次递增条件下, MAE 值的变化,对比结果如图 2 所示,这里直接引用文献^[11]中算法的实验结果,横坐标表示邻居用户数量 K 的取值,纵坐标表示平均绝对误差 MAE 的大小。




图 2 TNB-CF 和 CF 的对比图

根据图 2,可以看出,随着邻居用户个数的增加,三个算法的 MAE 值都逐渐减小,说明推荐的准确率也逐渐变大.但是传统的 CF 算法随着邻居用户数量的增加其预测精度的提高明显变小,当邻居用户个数达到 60 以上时, MAE 值变化不大.本文提出的 TNB-CF 算法,其 MAE 值要小于传统的 CF 算法,在邻居用户个数不到 50 个时,这种优势不太明显,但是邻居用户个数超过 50 时, TNB-CF 算法的预测精度非常明显的高于传统 CF 算法.这是由于随着数据稀疏度逐渐增大,能够和目标用户计算相似度的用户越来越少,目标用户在确定最近邻居时,并没有足够多的用户可以计算预测评分. TNB-CF 算法与基于改进信任的协同过滤算法认为在推荐算法中引入信任度是可行的,主要区别在于全局信任度的计算上以及信任的传递性.本文考虑得更加全面,考虑了用户活跃度和用户权威度来衡量用户全局信任度,从而产生了更高的推荐准确度.

本文提出的 TNB-CF 算法根据信任关系的传递性,可以为目标用户匹配到更多可靠的邻居用户,扩大邻居用户的范围,提高系统查全率;另一方面, TNB-CF 算法改进了原有的相似度计算方法,将信任度作为相似度计算的一个补充,通过对信任度矩阵和相似度矩阵合并,得到一个更加稠密的新矩阵,能够提高系统推荐的精确度.对于冷启动问题,基于信任的推荐系统中,只要新用户有一个信任的朋友,就可以根据信任的传递性为该用户查找到更多的邻居用户,在此基础上可以对新用户进行推荐.如果新用户一个信任的朋友也没有,可以将系统中的用户按照其全局信任

度高低公式(9)进行排序,从中选取全局信任度较高的几位用户供新用户选择,一旦用户确定一个朋友,系统就可以继续为新用户进行推荐.

4 结语

本文把信任引入到传统的协同过滤算法中,并结合信任度和相似度两个因素确定邻居用户,以信任度和相似度结合的混合值作为推荐权重,并从局部信任度和全局信任度来计算信任度,把用户活跃度和用户权威度作为影响全局信任度的重要因素.实验说明,本文提出的全局信任度度量方法合理,且改进后的算法 TNB-CF 能为目标用户带来更多的邻居用户,有效缓解数据稀疏问题,提高系统推荐的准确度.

参考文献

- Xue G, Lin C, Yang Q, et al. Scalable collaborative filtering using cluster-based smoothing. Proc. of the 28th annual int. ACM SIGIR Conf. on Research and Development in Information Retrieval. 2005
- 石昌显.结合用户背景信息的协同过滤推荐算法研究[学位论文].兰州:兰州大学,2009.
- 潘红艳,林鸿飞,赵晶.基于矩阵划分和兴趣方差的协同过滤算法.情报学报,2006,25(1):55-59.
- 王稳寅.针对冷启动推荐的分布式协同过滤研究[学位论文].上海:上海交通大学,2012.
- 李聪.电子商务协同过滤可扩展性研究综述.现代图书情报技术,2010,(11): 37-44.
- Lee TQ, Park Y, Park YT. A time-based approach to effective recommender systems using implicit feedback. Expert Systems with Applications, 2008, 34(4): 3055-3062.
- 甘早斌,曾灿,李开,等.电子商务下的信任网络构造与优化.计算机学报,2012,(1):27-37.
- O'Donovan J, Smyth B. Eliciting trust values from recommendation errors. Proc. of the 18th Int. Florida Artificial Intelligence Research Society Conference, 2005. 289-294.
- 俞琰,邱广华.融合社交网络的协同过滤推荐算法研究.现代图书情报技术,2012,(6):54-59.
- 郭艳红.推荐系统的协同过滤算法与应用研究[学位论文].大连:大连理工大学,2008.
- 金亚亚,牟援朝.基于改进信任度的协同过滤推荐算法.现代图书情报技术,2010,(10):49-53.
- Ziegler C, Georg L. Analyzing correlation between trust and user similarity in online communities. Proc. of Second International Conference on Trust Management. 2004.