

1-3-2019

## Research of Analysis Method of Presenters' Reputation Record

Zhiyong Yu

*Zhengzhou Institute of Information Science and Technology, Zhengzhou 450001, China;;State Key Laboratory of Mathematical Engineering and Advanced Computing, Zhengzhou 450001, China;*

Wang Na

*Zhengzhou Institute of Information Science and Technology, Zhengzhou 450001, China;;State Key Laboratory of Mathematical Engineering and Advanced Computing, Zhengzhou 450001, China;*

Niu Kan

*Zhengzhou Institute of Information Science and Technology, Zhengzhou 450001, China;;State Key Laboratory of Mathematical Engineering and Advanced Computing, Zhengzhou 450001, China;*

Jindong Wang

*Zhengzhou Institute of Information Science and Technology, Zhengzhou 450001, China;;State Key Laboratory of Mathematical Engineering and Advanced Computing, Zhengzhou 450001, China;*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

---

## Research of Analysis Method of Presenters' Reputation Record

### Abstract

**Abstract:** In order to satisfy the requirement of service presenters' credibility from recommendation system, this paper put forward a method based on the analysis of reputation record to find the most credible presenters. The preference similarity between different users is calculated with users' preference vectors. The *relevance of the fields, recommendation response rate and recommendation satisfaction rate* are then calculated to filter the presenters. *The presenters' current reputation is calculated by introducing the penalty factor.* We filter the presenters' reputation record with *localized changes and tendentious changes and calculate the skewness coefficient and kurtosis coefficient of the reputation records.* We get the presenters' excellent reputation values combined with the expectation and variance to choose the credible presenters. The experimental results show that this method can improve the accuracy of presenters' reputation calculation and the effectiveness of service recommendation.

### Keywords

presenter discovery, reputation analysis, recommendation credibility, curve analysis

### Recommended Citation

Yu Zhiyong, Wang Na, Niu Kan, Wang Jindong. Research of Analysis Method of Presenters' Reputation Record[J]. Journal of System Simulation, 2018, 30(12): 4625-4635.

## 服务推荐者声誉记录分析方法研究

于智勇<sup>1,2</sup>, 王娜<sup>1,2</sup>, 牛侃<sup>1,2</sup>, 王晋东<sup>1,2</sup>

(1.信息工程大学, 河南 郑州 450001; 2.数学工程与先进计算国家重点实验室, 河南 郑州 450001)

**摘要:** 为了满足推荐系统对服务推荐者可信性的要求, 提出一种基于声誉记录分析的可信推荐者发现方法, 通过用户偏好向量计算不同用户间的偏好相似度, 计算领域相关度、推荐响应率、满意率并对推荐者进行过滤, 通过引入惩罚因子计算推荐者当前声誉, 对推荐者声誉记录进行定域改变和倾向改变过滤, 计算出声誉记录的偏度系数和峰度系数, 结合期望与方差确定推荐信任源。实验结果表明, 该方法可以提高推荐者声誉计算准确性, 寻找到更为可信的推荐者从而提升服务推荐的有效性。

**关键词:** 推荐者发现; 声誉分析; 推荐可信度; 曲线分析

中图分类号: TP391 文献标识码: A 文章编号: 1004-731X (2018) 12-4625-11

DOI: 10.16182/j.issn1004731x.joss.201812017

### Research of Analysis Method of Presenters' Reputation Record

Yu Zhiyong<sup>1,2</sup>, Wang Na<sup>1,2</sup>, Niu Kan<sup>1,2</sup>, Wang Jindong<sup>1,2</sup>

(1.Zhengzhou Institute of Information Science and Technology, Zhengzhou 450001, China;

2. State Key Laboratory of Mathematical Engineering and Advanced Computing, Zhengzhou 450001, China)

**Abstract:** In order to satisfy the requirement of service presenters' credibility from recommendation system, this paper put forward a method based on the analysis of reputation record to find the most credible presenters. The preference similarity between different users is calculated with users' preference vectors. The *relevance of the fields, recommendation response rate and recommendation satisfaction rate* are then calculated to filter the presenters. *The presenters' current reputation is calculated by introducing the penalty factor.* We filter the presenters' reputation record with *localized changes and tendentious changes and calculate the skewness coefficient and kurtosis coefficient of the reputation records.* We get the presenters' excellent reputation values combined with the expectation and variance to choose the credible presenters. The experimental results show that this method can improve the accuracy of presenters' reputation calculation and the effectiveness of service recommendation.

**Keywords:** presenter discovery; reputation analysis; recommendation credibility; curve analysis

### 引言

在云环境中, 各种资源被动态地连接到

Internet 上, 通过 Internet 提供服务。然而用户在使用服务之前无法判断服务的质量及其可靠性、可信性, 需要服务推荐者对服务进行推荐。因此服务推荐者可信是保证服务推荐信息可用及有效的关键。

针对上述应用需求, 本文提出一种基于声誉记录分析的服务推荐者发现方法。首先引入用户偏好相似度对服务推荐者进行过滤, 得到推荐者初始



收稿日期: 2016-12-05 修回日期: 2017-02-15;  
基金项目: 国家自然科学基金(61303074);  
作者简介: 于智勇(1992-), 男, 辽宁大连, 硕士, 研究方向为服务信任评估; 王娜(1966-), 女, 河南郑州, 硕士, 副教授, 研究方向为云计算、信息安全; 牛侃(1989-), 男, 北京, 硕士, 研究方向为云资源调度。

<http://www.china-simulation.com>

• 4625 •

集,然后通过计算推荐者的领域相关度、推荐响应率和推荐满意率得到推荐者候选集,最后计算推荐者的声誉值,通过历史声誉分析与预测方法确定推荐信任源。将推荐信息合成,帮助服务推荐信息请求者挑选最可靠的服务。本文提出的方法,很好的利用了系统现有的用户交互数据,减少信息收集开销,提高了服务信任评估效率,提高了寻找服务推荐者的准确率,进而提高用户选取优质服务的准确率。本文第2节总结了当前协同推荐的研究现状,并给出基于声誉的云服务系统中交互信息在主体中的存储方式,以及服务满意度、推荐者声誉等相关定义。第3节详细论述了基于声誉记录分析的服务推荐者发现方法,包括利用偏好相似度划分推荐空间,以及通过推荐历史与用户声誉的最终推荐信任源的获取方法。第4节给出关于服务选取的模拟实验,验证该方法在可信服务选取中的效果。第5节对全文工作进行总结。

## 1 相关工作

基于协同推荐机制的服务推荐已经取得大量研究成果。Kim等<sup>[1]</sup>将服务运行结果的反馈由一个全局的权威中心存储和管理,并根据交易过程的相关因素提出一种较灵活的信任评估方法。Ma等<sup>[2]</sup>提出一个服务评价收集机制,服务交互信息交由一个绝对可信的第三方节点管理,并负责进行服务的信任评估。Tang等<sup>[3]</sup>定义用户对推荐者的信任程度作为推荐信息的权重,通过相关因子加权得到关于服务的推荐度。王刚等<sup>[4]</sup>通过组建信任网络,根据连接关系传递和共享服务推荐信息,并依据链路长度给推荐者赋予权重。Park等<sup>[5]</sup>将交易相关特征和服务反馈融合到信任评估模型中,通过加入时间衰减和事件影响因子,在服务交互反馈的基础上计算服务信任度,提高了算法抵抗恶意节点的能力。潘静等<sup>[6]</sup>提出一种基于声誉的推荐者发现方法,通过相关因子来度量推荐信任关系,通过信任的传递和迭代计算出推荐者声誉值,选取高声誉值的推荐者进行服务推荐度计算。甘早斌等<sup>[7]</sup>提出一种基于声

誉的多维度信任算法,设定自信因子将直接信任和推荐信任进行综合,并将交易评价体系和权重体系引入多维度机制,增强了信任算法的敏感性。Jeffrey等<sup>[8]</sup>首次提出领域相关模型TBM在不同的领域中评估用户声誉,结合真实数据对算法进行验证,相比于其他声誉算法更加有效和强健。

分析现有的协同推荐<sup>[9]</sup>机制,可以发现其主要思路是通过收集和整理推荐者对服务的使用评价,保证用户在进行服务选取时有足够多的较为权威的推荐意见来帮助决策。目前协同推荐机制可以分为两种,一种是集中式的协同推荐机制,由具有权威性的节点来集中管理网络中主体对服务使用的反馈经验,通过合并使用经验得到目标服务的信任评估值或推荐度,以此为用户提供服务选取的建议。这种机制架构简单,易于开发实现,但存在单点故障的问题。另一种是分布式的协同推荐机制,节点之间通过信任关系或者交互关系而组成网络进行推荐信息共享,将所有的推荐信息收集后再依照某种算法进行加权计算,得到目标服务的信任评估值或推荐度。分布式的协同推荐机制中没有权威节点对用户主体进行管理,不能保证其推荐信息的可靠性与可信性,而且开放性、动态性的特征使得系统中主体可以自由的加入或离开,对推荐信息的可达性、有效性都有影响。

云环境下服务系统中实体可以分为两大类:主体,指用户,即是服务使用者也是服务推荐者;服务,分布在云环境下的服务。主体使用服务并评价服务运行结果,主体之间通过分享关于服务使用的经验信息,形成推荐关系。

本文设定每个主体在本地存放历史交互记录以及个人信任信息。历史交互记录包括历史推荐者交互记录与历史服务交互经验库,历史推荐者交互记录主要存放主体与服务推荐者的交互数据,包括与历史推荐者交互次数、响应次数、交互满意次数与不满意次数以及每次推荐的服务的交易金额等服务信息,用于推荐者的推荐响应率和推荐满意率的计算。历史服务交互经验库主要存放主体与服务

间的交互信息, 包括交互时间、金额、服务属性满意度评价、服务总体评价等信息。用于计算对服务的推荐度和主体声誉的计算。个人信任信息包括主体对服务个性化偏好<sup>[11]</sup>描述和个人声誉记录。由于每个用户在选择和评估服务时都具有个性化的偏好选择需求, 偏好相似度高的用户对服务的评判标准较为相近。在进行服务推荐信任源选取时更具有可信度。个人声誉记录用来记录主体声誉值在系统中随时间的变化情况, 通过对主体声誉值的分析与预测, 以此来确定推荐信任源。对文中计算与使用的指标与相关参数定义如下:

定义 1 (服务满意度) 是指主体根据自身主观偏好对所使用服务的表现做出的主观评价, 这里是用用户主体综合服务各方面表现给出的满意度评价, 主要用于更新推荐者的推荐结果和更新用户与服务交互记录, 计算用户对服务的推荐度;

定义 2 (推荐信任度) 信任是指一个主体对另一个主体的行为和言语或具有完成某项任务能力的相信程度。推荐信任度指的是推荐信息请求者对推荐者推荐行为的相信程度, 用于筛选具有高可信度的推荐者和计算推荐者的声誉;

定义 3 (推荐者声誉  $R_t$ ) 声誉是指一个主体在一个群体中被所有主体认可的程度, 推荐者声誉是指一个主体的推荐行为被一个群体的认可程度;

定义 4 (推荐响应率  $R_r$ ) 是指推荐者响应推荐请求信息的次数在收到的推荐请求信息的总数中的比例。用来衡量推荐者在系统中的参与度, 同时也可以过滤坏节点或者已弃用的节点;

定义 5 (推荐满意率  $R_s$ ) 是指用户使用推荐者推荐的服务后给出满意反馈的次数在推荐者所有推荐次数中的比例。用来表征推荐者推荐质量同时也用来计算推荐者声誉值。

## 2 基于声誉的服务推荐者发现方法

通过分析现有的推荐系统, 发现现有系统在考虑推荐者信任度方面还存在很多问题, 大部分系统都将推荐者与用户的评分相似度<sup>[12]</sup>作为衡量推荐

者信任度的标准, 具有很大的局限性和误差, 基于推荐者声誉的推荐系统大多使用用户交互数量的加权综合、相邻节点评价的加权拟合或通过邻接图上使用 PageRank 算法<sup>[13]</sup>来计算推荐者的声誉, 这些方法虽然具有一定的可行性与有效性, 但其在计算声誉值时考虑不全面, 没能将关于推荐者声誉的各方面信息都纳入计算。

本文提出基于声誉记录分析的服务推荐者发现方法, 在现有系统的基础上, 尽量减少系统开销和用户操作繁琐程度, 充分利用现有数据, 通过计算推荐声誉, 并对推荐声誉进行分析和预测, 以此来确定推荐信任源。整个方法的基本步骤如下:

1. 目标用户在系统中发布某个服务的推荐信息请求, 根据该服务的交互记录, 找到使用过该服务的所有用户, 组成推荐者集合;
2. 计算集合中推荐者与目标用户的偏好相似度, 根据计算结果对集合中的推荐者进行筛选, 排除相似度太低的推荐者, 得到推荐者初始集;
3. 根据推荐者的推荐记录, 计算推荐者的推荐响应率、推荐满意率、领域相关度, 根据计算结果对推荐者初始集进行筛选, 形成推荐者候选集;
4. 计算推荐声誉, 加入到推荐者个人声誉记录中;
5. 对推荐者声誉记录进行分析和预测, 根据相关过滤条件, 对推荐候选集进行过滤, 取得推荐信任源;
6. 计算得到服务推荐度, 用户选择服务进行交互, 根据用户交互结果更新推荐者声誉。

### 2.1 推荐者初始集确定

服务具有众多属性, 而不同的用户由于对服务的使用期望不同, 使用环境不同, 因此对服务的属性具有不同的偏好, 对于同一服务不同用户可能给出不同的推荐度, 如果在推荐系统中无差别的采纳推荐者的推荐, 将很难计算出针对目标用户具有高推荐度的服务。因此, 用户间对服务的特征属性的评价指标权重的相似度是选取推荐者的一个重要

衡量标准。

设推荐信息请求者  $U_a$  在系统中请求服务  $S_b$  的推荐信任度, 系统中每个服务都包含  $l$  个属性  $\{f_1, f_2 \cdots f_l\}$ , 用户  $U_a$  对服务属性的偏好向量为  $W_a = (w_{a1}, w_{a2} \cdots w_{al})$ , 系统中推荐者  $U_i$  对服务属性的偏好向量为  $W_i = (w_{i1}, w_{i2} \cdots w_{il})$ , 其中  $\forall w_{ij} \in [0, 1]$ ,  $\sum_{j=1}^l w_{ij} = 1$ 。由于偏好向量的各分量的量纲、数量级以及指标优劣的取向均相同, 因此采用余弦相似度<sup>[14]</sup>可以很好的计算出偏好向量间的相似程度, 从而较为准确的找到偏好相近的推荐者。用户  $U_a$  与  $U_i$  间偏好相似度  $Sim_p(U_a, U_i)$  的计算公式为:

$$Sim_p(U_a, U_i) = \frac{\sum_{j=1}^l w_{aj} w_{ij}}{\sqrt{\sum_{j=1}^l w_{aj}^2} \sqrt{\sum_{j=1}^l w_{ij}^2}} \quad (1)$$

用户与服务的交易记录的参考价值会随着时间的增长而逐渐降低, 距离当前时刻太远的交易记录已经不具有参考价值, 应不予考虑, 因此设定时间窗口  $[t_s, t_c]$ , 其中  $t_s$  为当前时刻,  $t_c$  为截止时刻。

系统根据服务  $S_i$  的交易记录寻找在时间窗口  $[t_s, t_c]$  中与其有过交易历史的用户, 组成推荐者集合, 记为  $U_{init} = \{U_1, U_2 \cdots U_m\}$ , 使用公式(1)分别计算推荐者集合中每个推荐者与目标用户间偏好相似度, 设定偏好相似度阈值为  $per$ , 对集合中的推荐者进行筛选, 将偏好相似度低于阈值的推荐者从集合中移除, 最终得到经过偏好筛选的推荐者初始集。

## 2.2 推荐者候选集划分

推荐者的推荐历史记录可以很好的反映其推荐能力和推荐可信度, 本文通过设定领域相关度、推荐响应率和推荐满意率来从不同方面反映推荐者的表现情况。

领域相关度<sup>[15]</sup>是指推荐者与目标服务所属的领域的相关程度, 推荐用户的领域相关度表示推荐用户对某类服务的了解和关注程度, 相关程度越高, 推荐者的推荐越有价值。因此在筛选推荐者时, 对于该服务领域的专家或对相关知识领域有深入

了解的用户应选作推荐者。本文通过推荐者与某个领域服务的交互次数的函数来量化领域相关性, 即  $\alpha = \sqrt{n/(n+1)}$ , 其中  $n$  为推荐者与某类服务的交互次数。

推荐响应率是指推荐者对于推荐信息请求的响应表现, 由于推荐者主观因素或者网络阻塞等原因, 推荐信息请求可能无法得到响应。推荐满意率表示用户对于推荐者的推荐的满意程度的统计量。推荐信息请求者在  $n$  次请求之后根据获得信息量对推荐者进行推荐响应率和满意率的预测。这个场景符合  $n$  重贝努里(Bernoulli)随机实验模型。现有推荐者初始集  $U_{init} = \{U_1, U_2 \cdots U_m\}$ , 设初始集中的推荐者  $U_i$  有推荐历史记录  $R_i$ , 记为  $R_i = \{rt_i, rb_i, rs_i, ru_i\}$ 。其中  $rt_i$  表示收到的推荐请求集合,  $rb_i$  表示推荐请求响应集合,  $rs_i$  表示推荐反馈满意集合,  $ru_i$  表示推荐反馈不满意集合。根据贝努里大数定律, 推荐响应率随着请求  $rt_i$  数量的增大将依照概率收敛于推荐响应的概率, 即  $Rr_i \leftarrow Num(rb_i)/Num(rt_i)$ ; 推荐满意率随着响应  $rb_i$  数量的增加将收敛于推荐满意的概率, 即  $Rsi \leftarrow Num(rs_i)/Num(rb_i)$ 。

设定推荐响应率、推荐满意率和领域相关度接受阈值, 针对推荐者初始集  $U_{init} = \{U_1, U_2 \cdots U_m\}$  中的所有推荐者, 根据阈值进行推荐者筛选, 将低于阈值的推荐者从初始集中移除。满足要求的推荐者组成推荐者候选集  $U_{cand} = \{U_1, U_2 \cdots U_n\}$ 。通过设定阈值大小调整推荐者候选集的规模, 以适应新进入网络的服务或主体因缺少交互而具有较少的历史用户或可信推荐者, 增加了计算灵活性。

## 2.3 推荐信任源计算

### 2.3.1 推荐声誉值计算

推荐者声誉<sup>[16]</sup>是根据用户间推荐交互历史形成的信任关系的传递和汇总, 它是主体群对某个主体推荐能力和信任程度的共识, 推荐的有效性与推荐者的行为特性相关, 如合谋欺骗和恶意推荐等。由于个人交互经验的有限性, 通常会因为与服务和推荐者的交互次数不多或者信任度不够等原因导

致误判, 但通过主体群的力量来衡量某个推荐者的声誉可以对推荐信息源进行过滤, 减少恶意推荐信息的影响。

定义 6 (惩罚因子  $\rho$ ) 表示对推荐者给予不真实推荐的惩罚, 根据信任的脆弱性, 较高信任度的推荐者出现不真实推荐行为后, 其信任度将大幅下降。

非诚信推荐者可能通过大量小额诚信交易推荐赚取较高的声誉, 从而进行大额度的推荐欺骗。为防止利用诚信小额交易推荐进行大额交易的恶意推荐, 本文在计算推荐信任度时引入交易金额影响因子  $\Phi(m_{ij})$ , 使交易金额越大的推荐交互记录对推荐信任度计算贡献越大, 反之则越小。计算公式为:  $\Phi(m_{ij}) = \exp(-1/m_{ij})$ , 其中  $m_{ij}$  表示推荐者  $U_i$  第  $j$  次推荐的交易金额。

推荐者的推荐历史记录参考价值会随着时间的增加而减弱, 因此设定参考记录的时间衰减因子  $\Psi(t_j)$ , 距离当前时刻越近的推荐记录对推荐信任度计算贡献越大, 反之则越小。计算公式为:  $\Psi(t_j) = \exp(-[(t_0 - t_j)/T])$ , 其中  $t_0$  表示当前时刻,  $t_j$  表示第  $j$  次推荐的发生时刻,  $T$  为间隔周期, 距离本次交互时刻越近的推荐记录对声誉的影响越大。

现有推荐者  $U_i$  推荐历史记录, 记为  $R_i = \{rt_i, rb_i, rs_i, ru_i\}$ 。其中  $rt_i$  表示收到的推荐请求集合,  $rb_i$  表示推荐请求响应集合,  $rs_i$  表示推荐反馈满意集合,  $ru_i$  表示推荐反馈不满意集合。由此我们可得推荐声誉计算公式为:

$$Rt_i = \alpha * Rr_i * \sum_{j \in rs_i} \Phi(m_{ij})\Psi(t_j) - \sum_{p \in ru_i} \rho\Phi(m_{ip})\Psi(t_p) \quad (2)$$

式中:  $\alpha = \sqrt{n/(n+1)}$  是领域相关度;  $n$  为推荐者使用该类服务的次数, 用来调节领域不同对声誉的影响;  $Rr_i = Num(rb_i)/Num(rt_i)$  为服务响应率, 响应率越高的用户其拥有更高的推荐者声誉, 由此可以起到激励作用, 提高推荐者的推荐积极性。  
 $\sum_{j \in rs_i} \Phi(m_{ij})\Psi(t_j)$  是根据推荐反馈满意记录计算得出的加权推荐满意度, 推荐者的满意度越高表明其

推荐的服务更可靠, 推荐者声誉越高。

$\sum_{k \in ru_i} \Phi(m_{ik})\Psi(t_k)$  是根据推荐反馈不满意记录计算得出的加权推荐不满意度。 $\sum_{p \in ru_i} \rho\Phi(m_{ip})\Psi(t_p)$  表示

对推荐者不真实推荐的惩罚,  $\rho$  为惩罚因子, 可以根据具体情况设定值的大小, 通过添加惩罚因子, 增加推荐者声誉计算的敏感性, 使得当推荐者出现不真实推荐时, 其声誉会有较大幅度下降。同时为惩罚因子添加时间和金额加权, 距离当前时刻越久惩罚越小, 保证推荐者的声誉可以依靠满意的推荐交互逐渐提升。当推荐者通过诚信小额交易积累推荐信任度时, 根据公式可知, 由于小额交易的交易金额影响因子很小, 因此对于推荐声誉的增长推动很小, 但当推荐者进行大额交易恶意推荐时, 在计算加权推荐不满意度时交易金额影响因子会比较大, 因此推荐者的推荐声誉会大幅度降低, 以此来惩罚推荐者的恶意推荐行为, 同时降低其推荐信任度, 避免其他用户采纳其恶意推荐。

从用户请求推荐信息的过程来看, 其推荐信息来自于使用过目标服务的主体。从另一方面来看, 对推荐信息请求者来说, 只向推荐者集合中  $k$  个具有优秀声誉的推荐者请求推荐信息, 而不考虑网络之外的陌生推荐者的使用经验, 因为向无从考查可靠性、可信性的信息源发送请求并接受推荐, 可能会增加信息发送时间、资源消耗以及评估和决策的风险。从发起服务推荐信息请求的主体出发, 通过推荐者之间的信任关系传递, 获得满足要求的推荐者候选集。算法 1 给出推荐者候选集构建算法。

算法 1 推荐者候选集构建算法

输入: 目标服务  $S_t$ 、所有主体信息。

输出: 推荐者候选集及其中每个主体的推荐声誉值。

1) if  $U_i \otimes S_t \text{ in } [t_s, t_c] \Rightarrow U_{start}$

根据服务  $S_t$  的交易记录寻找在时间窗口  $[t_s, t_c]$  中与其有过交易历史的用户, 组成推荐者集合;

2) if  $Sim_p(U_a, U_i) > per \Rightarrow U_{init}, (U_i \text{ in } U_{start})$

根据公式(1)计算推荐者与请求用户间偏好相

似度, 设定偏好相似度阈值为  $per$ , 对集合中的推荐者进行筛选, 得到经过偏好筛选的推荐者初始集;

3) get  $\alpha, Rr_i, Rs_i$  and filtrate  $\Rightarrow U_{cmd}, (U_i \text{ in } U_{init})$

计算推荐者初始集中推荐者的领域相关度、推荐响应率和推荐满意率, 设定接受阈值, 对初始集进行筛选, 得到推荐者候选集;

4) get  $Rt_i$  with formula(2),  $(U_i \text{ in } U_{cmd})$

根据公式(2)计算推荐者候选集中主体的推荐声誉。

### 2.3.2 声誉记录分析与预测

传统方法选取具有高声誉的前  $k$  个推荐者作为服务的推荐信任源<sup>[17]</sup>, 然而推荐者声誉是一个随时间变化的动态值, 只通过判断当前时刻声誉值的高低来确定推荐者的可信性具有一定的局限性, 本文我们通过绘制推荐者声誉记录的折线图, 通过折线图来分析和预测推荐者的声誉, 以此来选取具有优秀声誉的推荐者。折线统计图不但可以表示出数量的多少, 而且还能够清楚的表示出数量增减变化的情况, 可以直观地反映这种变化以及各组之间的差别。推荐者的声誉记录存储在主体本地, 可以设定时间间隔来绘制声誉折线图, 这里选取时间间隔为 12 h, 例如图 1 所示。




图 1 推荐者声誉折线图

Fig. 1 Line chart of presenters' reputation

折线图中有连续  $n$  个点持续升高或降低的情况叫做倾向改变,  $n$  是人为设定值。倾向改变状态代表的是数据变化的趋势, 因此可以对数据进行预测。如果推荐者声誉记录在当前时刻处于倾向降

低, 则说明其近期处于不诚实推荐或者请求无响应等非理想状态, 因此可以考虑将其移除推荐者候选集。可以通过设定倾向降低的时间阈值  $Qt$ , 将超过阈值的推荐者移除。例如设定  $Qt$  为 10 个时间周期, 图 1 中第 11 个时间周期为当前时刻, 由图可知推荐者  $U_3$  在时间阈值  $v$  内一直处于倾向降低, 说明推荐者  $U_3$  处于非正常状态, 因此将其从推荐者候选集中移除。

折线图中有连续  $m$  个点处于设定界值  $Dt$  上侧或下侧的情况叫做定域改变,  $m$  是人为设定值。它代表数据长时间大于或者小于设定界值  $Dt$ , 因此我们可以通过定域改变预测数据在下一阶段的取值范围。如果推荐者声誉记录在当前时刻处于设定界值下侧的定域改变状态, 其声誉值稳定在设定界值下侧, 说明推荐者的推荐能力不强或者推荐可信性较低等导致其推荐声誉长时间偏低, 可以考虑将其移除推荐者候选集。通过设定  $m$  值的大小, 当  $m$  足够大时, 可以表明推荐者的声誉稳定在设定界值以下。例如设定  $m$  为 10, 界值  $Dt$  为 0.5, 图 1 中第 11 个时间周期为当前时刻, 由图可知推荐者  $U_1$  在当前时刻处于界值 0.5 下侧的定域状态, 可以将其移除推荐者候选集; 推荐者  $U_2$  虽然当前时刻声誉值低于界值 0.5, 但其并未处于定域状态, 因此可以保留。

偏度(skewness)是统计数据分布偏斜方向和程度的度量, 是统计数据分布非对称程度的数字特征。当数据分布关于均值(期望)左右对称时, 偏度系数为 0。当偏度系数大于 0 时, 该分布为右偏态, 此时大于均值的数据比小于均值的少。当偏度系数小于 0 时, 该分布为左偏态, 此时小于均值的数据比大于均值的少。因此我们可以利用偏度系数对推荐者声誉记录进行分析, 当两个声誉记录的期望相同时, 通过比较偏度系数可以找到更优秀的声誉记录。通过偏度系数的特点可知, 偏度系数越小, 数据往大于期望的方向的偏移越大, 大于期望的数据个数越多, 表明用户的声誉数据更多的稳定在大于期望的某个值。偏度系数较大时, 则说明用户的声



誉数据大多小于期望值, 依靠少量的高声誉值将期望提高, 表明其声誉记录并不稳定且普遍低于期望值。因此, 在相同期望的情况下, 偏度越小, 声誉记录越优秀。本文使用三阶中心矩计量的偏度系数。该偏度系数是用三阶中心矩除以标准差的 3 次方来度量偏斜程度, 根据本文数据给出偏度系数  $SK$  计算公式为:

$$SK = \frac{\sum_{i=1}^N (X_i - \bar{X})^3}{N\sigma^3} \quad (3)$$

式中:  $\sigma = \sqrt{E(X - EX)^2}$ ;  $EX$  和  $\bar{X}$  为声誉记录的期望;  $N$  为声誉记录数据个数。

峰度(kurtosis)是用来反映频数分布曲线顶端尖峭或扁平程度的指标。其可以用来度量数据在中心聚集程度。有时两组数据的期望、标准差和偏态系数相同, 但他们分布曲线顶端的高耸程度却不同。统计上使用四阶中心矩来测定峰度系数, 因为偶阶中心矩的大小与图形分布的峰度有关。其中二阶中心矩就是数据的方差, 表明数据的波动情况, 可以在一定程度上反映分布的峰度, 但有时方差相同的数据却有不同峰度, 因此就利用四阶中心矩来反映分布的尖峭程度。为了消除变量值水平和计量单位不同的影响, 通常使用四阶中心矩与  $\sigma^4$  的比值作为衡量峰度的指标, 作为峰度系数。因此我们可以利用峰度系数来计算推荐者声誉记录的稳定程度, 方差和峰度系数越小, 表明声誉记录越稳定, 推荐者越优秀。给出峰度系数  $KU$  计算公式为:

$$KU = \frac{\sum_{i=1}^N (X_i - \bar{X})^4}{(N-1)\sigma^4} \quad (4)$$

式中:  $\sigma = \sqrt{E(X - EX)^2}$ ;  $EX$  和  $\bar{X}$  为声誉记录的期望;  $N$  为声誉记录数据个数。

由此本文给出优秀声誉  $Rb_i$  计算公式为:

$$Rb_i = \frac{\varphi(\sigma^2)Rt_i + (1 - \varphi(\sigma^2))EX \times (e^{SK} + 1)^{-1}}{\ln(KU)^2} \quad (5)$$

式中:  $Rt_i$  为当前时刻的声誉值;  $\varphi(\sigma^2) = \lambda^{\min(\frac{1}{\sigma^2}, 1)}$ ;  $\sigma^2$  为声誉记录的方差;  $\lambda$  为权重初始值。方差  $\sigma^2$  越大, 说明声誉记录波动越大, 推荐者声誉稳定性越差, 因此在计算优秀声誉时给予当前时刻声

誉值  $Rt_i$  的权值应该越小, 给予期望  $EX$  的权值应该越大, 因为在声誉记录波动性较大时, 当前时刻声誉值  $Rt_i$  对推荐者声誉总体的代表性较弱, 应该更多的关注声誉值期望。通过权重函数  $\varphi(\sigma^2)$  可以很好的根据方差动态改变权重分配。偏度系数  $SK$  表示声誉数据相对于期望  $EX$  的偏移程度, 因此将  $SK$  经过运算后与期望  $EX$  结合, 使得偏移系数  $SK$  越小时, 计算结果越大。峰度系数  $KU$  代表声誉数据的峰度, 因此通过  $\ln(KU)^2$  的形式实现峰度系数  $KU$  对优秀声誉  $Rb_i$  的调节。推荐者的优秀声誉  $Rb_i$  可以更加全面的描述推荐者的声誉, 因此可以选择  $Rb_i$  计算值最高的前  $k$  个推荐者作为最终的推荐者(推荐信任源)。算法 2 给出推荐信任源选择算法。

算法 2 推荐信任源选择算法

输入: 推荐者候选集中所有主体的声誉记录。  
输出: 推荐信任源。

1) if  $Qt_i > Qt$ , remove  $U_i$  from  $U_{cmd}$

设定倾向降低的时间阈值  $Qt$ , 将当前时刻处于倾向降低且超过阈值的推荐者从推荐者候选集中移除;

2) if  $m_i > m$  and  $Dt_i < Dt$ , remove  $U_i$  from  $U_{cmd}$

设定定域改变中  $m$  值和接受界值  $Dt$ , 将当前时刻处于定域降低且声誉值低于界值  $Dt$  的推荐者从推荐者候选集中移除;

3) get  $SK_i, KU_i, Rb_i (U_i \text{ in } U_{cmd})$

根据公式(3)计算出偏度系数  $SK$ , 根据公式(4)计算出峰度系数  $KU$ , 根据公式(5)得到推荐者的优秀声誉  $Rb_i$ ;

4) select top  $k$  presenters with highest  $Rb_i$

根据优秀声誉  $V$  计算结果, 选取前  $k$  个具有最高  $Rb_i$  的推荐者作为推荐信任源。

2.4 推荐记录更新

本文对服务推荐度计算方法不作详细探讨, 沿用传统的协同推荐机制, 发送请求推荐的信息, 对推荐信任源返回的推荐信息进行收集和整合。这里

使用以优秀声誉值  $Rb_i$  为权重的推荐信息聚合方法来计算服务推荐度  $Re p_{S_i}$ 。设目标服务  $S_i$ ,  $Sat_{t,i}$  为推荐者  $U_i$  对服务  $S_i$  的满意度,  $E_{set}$  为推荐信任源集合。则服务  $S_i$  的推荐度  $Re p_{S_i}$  计算公式为:

$$Re p_{S_i} = \sum_{U_i \in E_{set}} \frac{Sat_{t,i} \times Rb_i}{\sum_{U_i \in E_{set}} Rb_i} \quad (6)$$

发起服务选取的用户将根据服务推荐度将候选服务排序, 选择推荐度最高的服务进行交互, 交互之后给出服务满意度评价。根据服务满意度评价更新推荐者的推荐记录。传统方法采用的是用户给予满意的评价时, 则服务推荐者记录中推荐满意次数加 1, 给出低满意度或者不满意时, 推荐者记录中推荐不满意次数加 1, 从而对推荐者的声誉进行更新。采用这种方法虽然计算简单, 但存在误差较大的问题, 因为在计算服务推荐度时推荐信任源中的推荐者每个人给出的服务满意度是不同的, 有的推荐者给出高满意度, 推荐使用此服务, 有的推荐者给出低满意度, 不推荐使用此服务。因此在更新推荐者推荐记录时, 应将用户给出的服务满意度评价与推荐者推荐时给出的满意度进行比较, 两者相近, 则说明推荐者给出的推荐建议是正确的, 应该将推荐满意次数加 1。两者相差较大, 则表明推荐者给出的推荐建议与现实不符, 应将推荐不满意次数加 1。

$Sat_{t,i}$  为用户  $U_i$  对服务  $S_i$  的满意度, 取值范围为 [0,5], 发起服务选取的用户  $U_a$  对服务  $S_i$  的满意度为  $Sat_{t,a}$ , 推荐者  $U_b$  对服务  $S_i$  的满意度为  $Sat_{t,b}$ , 推荐真实度  $TR_{a,b}$  可以定义为  $TR_{a,b} = |Sat_{t,a} - Sat_{t,b}|$ ,  $Tr$  为真实度判定阈值, 当  $TR_{a,b} \leq Tr$  时, 表明推荐者给出的服务满意度与真实情况相近, 因此更新推荐者的推荐满意次数; 当  $TR_{a,b} > Tr$  时, 说明推荐者给出的服务满意度与真实情况不符, 因此更新推荐者的推荐不满意次数。

### 3 模拟实验与结果分析

为了验证本文提出的基于声誉记录分析的服务推荐者发现方法在寻找可信推荐者上的准确性

和有效性, 使用 `peersim` 网络节点以及拓扑关系的模拟平台, 构建一个服务选取的应用场景。在该场景中一个节点代表一个用户主体, 同时设置服务主体, 系统计算服务推荐度反馈给用户, 用户选择服务进行交互后给出本次交互的推荐度, 系统再根据新的交互记录更新服务推荐度。模拟平台按照轮次运行, 每一轮次中, 每个用户主体发起一次服务选取, 过程包括计算推荐者的优秀声誉、确定推荐信任源、向推荐者请求推荐信息、合并推荐信息、选取推荐度最高的服务进行交互、记录交互结果并更新推荐记录。

#### 3.1 实验场景设置

模拟实验场景设置包括服务模型与用户模型的配置, 服务模型包含服务数量及其相关属性。设定服务选取的环境中有 100 个服务, 记为  $S = \{S_1, S_2, \dots, S_{100}\}$ 。其中每个服务的满意度表现值初始化为 [0,5] 区间的值, 在每次进行服务调用时满意度表现值遵从正态分布概率函数  $N(\mu, \sigma^2)$ , 其中  $\mu$  为初始化的服务满意度表现值,  $\sigma^2$  则为每次调用服务时服务实际运行与初始化满意度表现值的偏差, 偏差的设定根据具体的服务的参数进行。服务的相关属性对于用户来说是透明的, 系统依靠推荐者的推荐信息计算服务推荐度, 用户通过给出的服务推荐度以此来判定服务性能。

用户模型包含用户数量以及行为属性。设定场景中有 500 个用户, 记为  $U = \{U_1, U_2, \dots, U_{500}\}$ 。行为属性包括用户的个性化偏好和是否为恶意主体。个性化偏好为用户对服务各属性的偏好程度。每次进行交互时, 普通用户会如实的给予推荐信息和服务满意度, 恶意用户会提供虚假的推荐信息和服务满意度。

服务平均满意度<sup>[18]</sup>(service satisfaction rate, SSR)描述所有用户在选取服务交互之后给出的服务满意度的均值, SSR 的大小与选取的服务质量密切相关, 因此可以直观的反映出可信推荐者选择算法的准确性。算法寻找到的推荐者越优秀, 则其推

荐的服务的质量越高, 相应的服务平均满意度越高。

### 3.2 实验结果与分析

本文选取潘静等<sup>[6]</sup>提出的基于声誉的推荐者发现 RRDA 方法与本文提出的算法进行比较, 评价他们在计算推荐者声誉值和寻找可信推荐者上的准确性差异, 以及抵抗恶意推荐的性能差异。

#### 3.2.1 算法准确性验证

实验首先比较算法在推荐者选取上的准确性, 采用 RRDA 算法、本文算法计算推荐者声誉值, 同时将本文算法中当前时刻声誉值  $R_{t_i}$  (简称 RT 方法) 也加入对比, 以此来比较本文算法中优秀声誉相比于当前时刻声誉更具有准确性。通过声誉值的计算选取前  $k$  个最可信的推荐者。每一轮中, 场景中每位用户选取推荐度最高的服务进行交互, 交互之后给出服务满意度。设置推荐者数量  $k=50$ , 服务表现方差  $\sigma^2 = 5$ , 实验重复 10 次, 记录每轮中所有用户对所选服务的平均服务满意度。则 RRDA 算法、本文算法以及当前声誉值  $R_{t_i}$  方法在性能上的差异如图 2 所示。

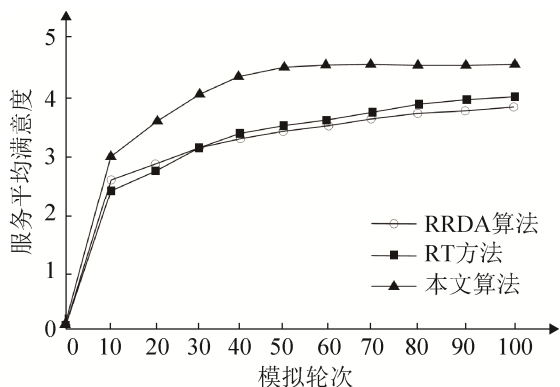


图 2 服务平均满意度对比

Fig. 2 Comparison of services' average satisfaction

图 2 中横坐标代表实验运行轮次, 每轮所有用户都发起一次服务选取行为, 纵坐标表示在该轮次运行之后, 所有用户对服务的平均满意度。从图中我们可以看出刚开始模拟时运行结果差别不大, 但随着服务选取次数的增加, 在 10~60 轮次本文算法拥有较快的收敛速度且 SSR 值稳定在 4.2 左右, 明

显优于其他两种方法。RRDA 算法与 RT 方法的满意度增长走势几乎相同, 两者最终 SSR 值稳定在 3.7 左右且 RT 方法的满意度稳定值略高于 RRDA 算法。

通过对算法和实验结果的分析我们可知, 随着模拟轮次的增加, 用户与服务交互经验逐渐增加, 推荐者的声誉建立起来, RT 方法在 SSR 上略优于 RRDA 算法, 主要原因是 RRDA 算法使用邻接图通过 PageRank 算法计算推荐者声誉, 而 RT 方法是基于时间和金额加权的推荐记录计算的声誉值, 因此在声誉计算准确性上高于使用 PageRank 方法, 所以得到的服务平均满意度略高于 RRDA 算法。而本文算法又明显优于 RRDA 算法和 RT 方法, 其关键在于本文提出的优秀声誉是在对推荐者声誉记录分析和预测的基础上计算得到, 通过绘制声誉折线图综合考虑声誉记录的分布特征及其变化趋势, 计算得到的优秀声誉相比于其他两种方法得到的声誉值能够反映推荐者更多的信息, 可以更加准确的找到可信推荐者, 因此在准确性上要明显优于 RRDA 算法和 RT 方法。

图 3 中纵坐标表示用户选中低质量服务的比率, 在实验场景中设置 60 个服务为低质量服务其余 40 个服务为高质量服务, 对比使用 3 种方法用户选中低质量服务的百分比。




图 3 低质量服务选中率

Fig. 3 Probability of selecting low quality services

从图 3 中我们可以看出, 实验初期到达 10 轮次时, 3 种算法的低质量服务选中率都大幅度下降到 0.35 左右, 随着实验轮次增多, 选中率逐渐趋

于稳定, 实验后期 80~100 轮次时, 本文算法低质量服务选中率稳定在 0.07 左右, 而 RRDA 算法和 RT 方法的选中率稳定值都稳定在 0.2 左右, 本文算法的选中率明显低于其他两种算法。

通过对算法和实验结果的分析可知, 实验初期用户与服务交互经验较少, 用户很难区分服务质量的高低, 随着模拟轮次的增加, 用户与服务交互次数增多, 推荐者声誉体系基本建立, 因此低质量服务选中率快速降低并逐渐达到稳定值。RRDA 算法与 RT 方法的选中率稳定值基本相同, 因为 PageRank 算法是推荐者信任度的传递和迭代, 与 RT 方法中计算声誉值的方法本质上相同的, 因此两种方法的性能大同小异。而本文算法能够更加全面的计算推荐者的声誉值, 在选择可信可靠的推荐者上要优于 RRDA 算法和 RT 方法, 因此低质量服务选中率要明显低于其他两种方法。

### 3.2.2 抗攻击能力

为了验证算法抵抗恶意推荐的能力, 设定 500 名用户中有 200 名恶意推荐者, 300 名普通推荐者, 对比 3 种算法计算得到的可信推荐者中恶意推荐者的百分比。

图 4 中纵坐标表示算法找到的可信推荐者中恶意推荐者的比例。从图 4 中我们可以看出, 实验初期直到 30 轮次时, 随着用户与服务交互次数的增加, 恶意推荐者比例迅速降低从初始的 0.4 下降到 0.1~0.15 之间。RT 方法与本文算法较 RRDA 算法下降的更为迅速。实验轮次到达中后期 70~100 轮次后, 恶意推荐者比例基本稳定, 本文算法稳定值最小在 0.025 左右, 而 RRDA 算法稳定值最大在 0.1 左右。本文算法降幅达到 0.375, 而其他两种方法在 0.3 左右。

通过对分析可知, 实验初期用户与服务交互经验较少, 无法有效的辨别恶意推荐者, 但本文算法和 RT 方法通过惩罚因子可以及时降低恶意推荐者声誉值, 快速而有效的屏蔽掉恶意推荐者。而单纯依靠 PageRank 方法计算声誉值的 RRDA

算法不能及时有效的对恶意推荐者做出反应, 因此其恶意推荐者比例下降速度较慢且稳定值高于其他两种方法。本文方法的恶意推荐者比例最终低于 RT 方法的原因在于, 本文方法通过对声誉记录的分析, 能够寻找到当前声誉较高的恶意推荐者并将其屏蔽掉, 因此抵抗恶意推荐者的能力优于 RT 方法。

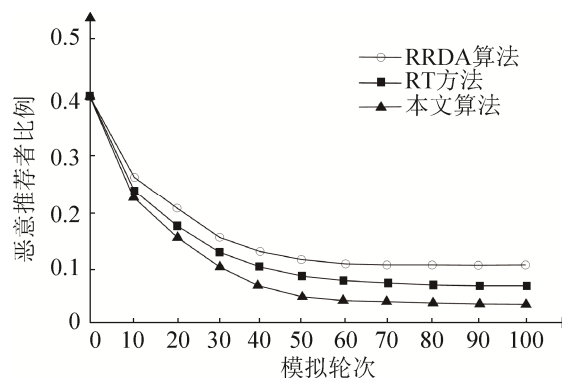


图 4 选中推荐者中恶意推荐者比例  
Fig. 4 Ratio of malicious presenters

## 4 结论

本文提出的基于声誉分析的可信推荐者发现方法在传统的推荐者发现方法的基础上进行了改进与创新, 其主要优点有: (一)本文算法在传统的基于时间金额加权的声誉值计算方法的基础上, 加入推荐响应率、领域相关度和惩罚因子, 激励推荐者积极提供推荐信息并惩罚恶意推荐者, 由此提高了推荐者声誉计算的准确性和抗恶意攻击能力; (二)提出推荐者声誉记录分析方法, 通过绘制声誉折线图, 结合定域、倾向改变、偏度系数和峰度系数等参数, 对声誉记录进行分析和预测, 不但提高了可信推荐者选取的准确性更加增加了抵抗恶意推荐者的能力。

同时本文算法也存在不足, 本文算法为了提升算法准确性, 在算法设计上相对复杂, 导致算法的计算复杂度较高, 计算耗时较长。在今后工作中, 我们将对本文算法进行复杂度上的优化, 提高算法运行效率, 并对推荐信息的有效收集以及推荐信任的传递和演化进行优化。

## 参考文献:

- [1] Kim Y A, Phalak R. A trust prediction framework in rating-based experience sharing social networks without a Web of Trust[J]. *Information Sciences (S0020-0255)*, 2014, 191(5): 128-145.
- [2] Ma Yin, Lu Haiwang, Gan Zengbin. Trust Inference Path Search with Minimum Uncertainty for E-commerce[C]// *Proceedings of the 10th Web Information Systems and Applications Conference*, Yangzhou, China, 2015: 133-137.
- [3] Tang Jiao, Gao Hu, Hu Xian, et al. Exploiting homophily effect for trust prediction[C]. *Proceedings of the 6th ACM International Conference on Web Search and Data Mining*. Rome, Italy, 2013: 53-62.
- [4] 王刚, 桂小林. 社会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.  
Wang Gang, Gui Xiaolin. Selecting and Trust Computing for Transaction Nodes in Online Social Networks[J]. *Chinese Journal of Computers*. 2013, 36(2): 368-383.
- [5] Kim S, Park H. Effects of various characteristics of social commerce(s-commerce) on consumers' trust and trust performance[J]. *International Journal of Information Management (S0268-4012)*. 2015, 33(2): 318-332.
- [6] 潘静, 徐锋, 吕建. 面向可信服务选取的基于声誉的推荐者发现方法[J]. *软件学报*, 2010(2): 388-400.  
Pan Jing, Xu Feng, Lv Jian. Reputation-Based Recommender Discovery Approach for Service Selection[J]. *Journal of Software*. 2010(2): 388-400.
- [7] 甘早斌, 丁倩, 李开. 基于声誉的多维度信任计算算法[J]. *软件学报*, 2011, 22(10): 2401-2411.  
Gan Zaobin, Ding Qian, Li Kai. Reputation-Based Multi-Dimensional Trust Algorithm[J]. *Journal of Software*. 2011, 22(10): 2401-2411.
- [8] LI Bincai, LI Ruihuan, Irwin King, et al. A topic-biased user reputation model in rating systems[J]. *Knowl Inf Syst (S0219-3116)*. 2015, 44(3): 581-607.
- [9] Wu Malin, Chang Cun, Liu Rui. Integrating content-based filtering with collaborative filtering using co-clustering with augmented matrices[J]. *Expert Systems with Application (S0957-4174)*, 2014, 41(6): 2754-2761.
- [10] 王海艳, 杨文彬, 王随昌, 等. 基于可信联盟的服务推荐方法[J]. *计算机学报*, 2014, 37(2): 301-311.  
Wang Haiyan, Yang Wenbin, Wang Suichang, et al. A Service Recommendation Method Based on Trustworthy Community[J]. *Chinese Journal of Computers*, 2014, 37(2): 301-311.
- [11] 张佩云, 陈恩红, 黄波. 基于社会网络面向个性化需求的可信服务推荐[J]. *通信学报*, 2013, 34(12): 49-59.  
Zhang Peiyun, Chen Enhong, Huang Bo. Personalized Requirements Oriented Trustworthy Services Recommendation Based on Social Network[J]. *Journal on Communications*, 2013, 34(12): 49-59.
- [12] Medo M, Wakeling J R. The effect of discrete vs. continuous-valued ratings on reputation and ranking systems[J]. *Europhys Lett (S0031-8949)*, 2015, 91(4): 236-244.
- [13] 尚燕敏, 张鹏, 曹亚男. 融合链接拓扑结构和用户兴趣的朋友推荐方法[J]. *通信学报*, 2015, 36(2): 117-125.  
Shang Yanmin, Zhang Peng, Cao Ya'nan. New Interst-sensitive and Network-sensitive Method for User Recommendation[J]. *Journal on Communications*, 2015, 36(2): 117-125.
- [14] Malik Z, Buguettaya A. Rateweb: Reputation assessment for trust establishment among web service[J]. *The VLDB Journal (S0949-877X)*, 2014, 18(4): 885-911.
- [15] Vadelou G, Ilavarasan E. Fusion of pearson similarity and slope one methods for QoS prediction for web services[C]. *2014 International Conference on Contemporary Computing and Informatics (IC3I)*, 2014: 27-29.
- [16] Rong-Hua Li, Jeffery Xu Yu, Xin Huang, et al. Robust reputation-based ranking on bipartite rating networks[C]. *Proceedings of the 2012 SIAM international conference on data mining*, 2015, 612-623.
- [17] Abdullah A, Xining Li. An integrated-model QoS-based graph for web service recommendation[J]. *2015 IEEE International Conference on Web Services (ICWS)*, 2015: 416-423.
- [18] Reformat Marek Z, Yager Ronald R. Suggesting recommendations using Pythagorean fuzzy sets illustrated using Netflix movie data[C]. *Communications in Computer and Information Science*, 2014: 546-556.