

基于推荐质量的信任感知推荐系统

王海艳 周 洋

(南京邮电大学计算机学院 南京 210003)

摘 要 推荐系统在解决信息过载方面已经取得了很大的成功,同时也存在数据稀疏、冷启动等问题。如何在评分数据稀疏的情况下获得满意的推荐成为推荐系统亟待解决的问题。将信任引入推荐系统成为解决上述问题的有效方法之一。已有的信任感知推荐系统大多基于布尔型信任关系,且没有考虑信任的领域相关性。在服务选择领域,服务请求者依据 QoS(quality of service)选择服务。联想到在服务推荐领域推荐请求者可以依据推荐质量(quality of recommendation, QoR)选择推荐用户,提出了推荐质量(QoR)的概念和基于推荐质量的信任感知推荐系统。QoR 的属性包含评价相似度、领域信任值、领域相关度和亲密程度,利用信息熵方法可确定各属性的权重。仿真表明该方法提高了推荐系统在数据稀疏情况下的精确度和评分覆盖率,有效提高了冷启动用户的召回率,在一定程度上解决了冷启动问题。

关键词 服务推荐,推荐质量,信任

中图法分类号 TP301.6 **文献标识码** A

Quality of Recommendation Based Trust-aware Recommender System

WANG Hai-yan ZHOU Yang

(College of Computer Science, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

Abstract Recommender system has achieved great success in dealing with information overload, meanwhile has some problems, such as data sparse, cold start and so on. How to get satisfied recommendation under the circumstance of data sparse is urgent for recommender system. Introducing trust into recommender system is an efficient way to resolve the above problems. Most of existing trust-aware recommender systems are based on Boolean trust relationship, and do not take domain correlation of trust into account. In the field of service selection, service requestor selects services based on QoS(quality of service). Inspired by QoS, recommendation requestor can find recommender based on QoR(quality of recommendation). Thus we put forward the concept of QoR and QoR based trust-aware recommender system. The attributes of qor include user rating similarity, domain trust, domain relative degree and social intimacy degree, whose weights are determined by method of information entropy. Empirical evaluation shows that our method improves the precision and rating coverage of recommender system under condition of data sparse, above all, effectively improves the recall rate of cold start user, resolving the cold start problem to some extent.

Keywords Service recommendation, Quality of recommendation, Trust

随着近些年 Web 服务规模的爆发性增长,如何有效地搜索到所需的 Web 服务成为服务计算领域亟待解决的问题^[1]。推荐系统作为解决信息过载的有效工具,按其所用的方法基本可以分为以下几种:基于内容推荐、协同过滤推荐、基于知识推荐和组合推荐。协同过滤(Collaborative Filtering, CF)是当前最成功的推荐技术之一^[2],其基本思想是通过分析兴趣爱好相似的用户或相似项目的评分信息来预测目标用户对特定项目的喜好程度。不过实际应用中 CF 系统的效率和精确度并不高,其主要原因在于用户—服务评分矩阵的稀疏性和高维性。绝大多数用户评过分的服务占服务总数的比例不到 1%^[3],如何在评分数据稀疏的情况下保证推荐系统的精

确度是服务推荐领域的一个核心问题。

解决评分数据稀疏的方法通常可以分为两类:第一类是归因(Imputation)和降维,用于优化推荐过程中相应阶段的计算公式和方法。归因基于某种填充策略对评分矩阵中的空缺数据进行填补,降维通过降低矩阵的维度减少无用信息,从而提高评分矩阵的密度,降低稀疏度。但填补数据容易导致用户个人特征数据的缺失,降维容易将有用的数据删除。第二类方法通过优化相似度计算、邻居选择和评分预测阶段的算法来降低数据稀疏性的影响。这类方法的缺点是改进的算法在挖掘有效数据的同时也扩大了错误数据的影响,降低了用户使用满意度。除了上述两类通用方法,将信任引入推荐系

到稿日期:2013-08-02 返修日期:2013-11-04 本文受国家自然科学基金(61201163),江苏省自然科学基金滚动资助项目(BK2011072)和江苏省博士后科研资助计划项目(1002005C)资助。

王海艳(1974—),女,博士后,教授,CCF 会员,主要研究领域为网格计算、服务计算、可信计算技术, E-mail: wanghy@njupt.edu.cn;周洋(1988—),男,硕士生,主要研究领域为服务推荐技术。

统也是解决数据稀疏问题的有效方法之一。相对于上述两类方法,基于信任感知的推荐系统的优势在于不需要做过多的工作,只需通过信任关系选择推荐用户完成推荐。近些年来社交网络的兴起,如全球范围内使用的 Facebook、Twitter,国内的人人网、朋友网以及各种网络社区等,给基于信任感知的服务推荐提供了很好的应用条件。其解决数据稀疏问题的思路是,当在用户作为冷启动用户或在服务评分数据稀疏的情况下不能有效选择推荐用户获取推荐服务时,可以通过用户间信任关系找出最信任的推荐用户集来推荐服务。

假定用户 A、B、C、D、E 间信任关系如图 1 所示。




图 1 用户信任关系图

推荐请求者(Recommendation Requester, RR) A, 向他的朋友或朋友的朋友请求推荐某一类服务, 推荐用户(Recommender)在收到请求通知后根据自己使用服务的情况推荐服务给 A。在之前的一些基于布尔型信任的推荐系统中, 推荐请求者将同一层推荐用户推荐的服务赋予同等权重, 如 A 将 B 和 C 的推荐同等对待。在现实生活中, 我们通常根据自身对推荐用户的信任程度, 对其推荐的服务抱以相应的采纳度, 因此有必要精确度量用户间的信任值。用户间信任值并不是固定不变的, 在推荐完成后应根据推荐请求者的满意程度更新相应的信任值。另外信任是领域相关的, 撇开具体领域单纯研究信任是没有意义的。若 A 的朋友 B 是医生, C 是汽车工程师, 在寻求医疗与汽车类的服务时, 在不同的领域对 B 和 C 的信任度是截然不同的, 显然在医疗领域, 对 B 的信任度较高, 对 C 的信任度较低, 在汽车领域则相反。

在服务选择领域, 服务请求者希望选择 QoS(Quality of Service)值高的服务, 体现在响应时间快、可靠性强等方面, 同理, 推荐请求者在选择推荐用户时希望选择 QoR(Quality of Recommendation)值高, 即推荐质量高的用户。要保证推荐质量高, 除了需要满足领域信任度高之外, 还应该满足一些其他属性。

本文针对上述问题提出了一种基于推荐质量的信任感知推荐系统。给出了在具体领域用户间信任值的度量和更新方法, 综合推荐请求者与推荐用户的评价相似度、领域信任值、亲密程度以及推荐用户的领域相关度, 提出推荐用户推荐质量的概念, 使用信息熵的方法确定各相关因素的权重。通过信任网络搜索出推荐质量满足设定值的 N 个用户作为推荐用户, 最后将预测评分高的服务推荐给源用户。本文第 1 节介绍背景及相关工作; 第 2 节介绍影响推荐质量的 4 个因素以及推荐质量的计算; 第 3 节给出本文的算法和体系结构; 第 4 节给出了仿真实验与结果分析; 最后对全文进行总结与展望。

1 背景及相关工作

Sinha 和 Swearingen^[4] 比较了用户从推荐系统和朋友那

里获取的推荐结果, 发现相对于 Amazon.com 之类的推荐系统中的陌生人, 人们更倾向于从朋友或熟悉的人那里获取推荐。社会学家指出社会影响(social influence)深深地影响着人们的选择, 这便是信任感知推荐系统的原理。图 2 形象地表示了信任感知推荐系统的推荐过程。

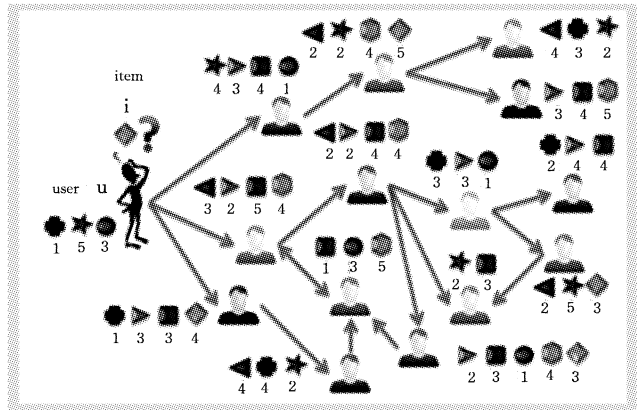


图 2 基于信任网络的推荐示意图

人们在做出选择的时候往往会参照与他们有着相似特点的人, 社会影响使得社交网络中相关的人互相影响而变得越来越相似。文献[5]通过实验验证了在社交网络中人们的行为与他们的信任邻居之间具有相似性, 它的结果和很多类似实验的结果证明了社交网络提供了一个独立的信息源, 它可以用来提高推荐的质量。

2004 年, Massa 首次将信任引入到推荐系统中^[6], 并提出了信任感知的推荐系统框架。它用用户之间的信任来代替协同过滤中用户相似度的作用, 但用户之间的信任是布尔型的, 信任表达能力弱。Xiao Cheng Chen 等^[7]将信任传播模型应用到协同过滤中。由于信任的传递, 该模型提高了预测精度和覆盖率, 并在一定程度上解决了冷启动问题。M. Jamali 和 M. Ester^[8]提出了一个名叫 TrustWalker 的随机游走算法, 结合基于项目的协同推荐与基于信任的推荐算法来对单个项目进行预测评分。文献[9]在 TrustWalker 的基础上提出 Top-N 推荐的算法, 每停留在一个用户上就推荐它评分最高的 K 个服务, 在一个用户上停留的概率与双方之间的评价相似度和距离相关。文献[10]提出了用户 T-index 的概念, T-index 值越大说明用户信任度越高。一个服务的 Toptrustee 由评价过此服务的 T-index 值高的用户组成, 在 Toptrustee 中可以找到传统方法获取不到的推荐用户, 该算法提高了推荐精度和覆盖率。以上模型都使用布尔型信任值。Yuanliang Gao 等^[11]融合社交网络中信任网络和改进的 CF 算法提出一个混合型推荐系统, 用户间直接信任值由用户自身给出, 间接信任值由基于信任传递距离和最长传递距离的公式加权算得。这种信任值的确立是比较主观的, 若存在如下情况, 一个用户给他一个很好的朋友定义了很高的信任值, 但他们的兴趣爱好却完全不相同, 基于这种主观信任值的推荐系统其精度必然不高。Punam Bedi 和 Ravish Sharma^[12]根据蚁群算法中信息素更新算法提出了用户间信任值的动态更新算法, 但是其信任初始值是通过用户评价相似度和双方共同评价服务数占各自评价总数的比例综合求得, 在评分数据稀疏的情况下这种方法存在严重缺陷。另外, 上述文献中的系统都没有考虑信任的领域相关性和影响用户推荐能力的其他因素。

同以上模型相比,本文的优势在于,依据推荐质量能选择出更符合推荐请求者要求的推荐用户。

2 推荐质量的计算

定义 1(推荐质量, Quality of Recommendation, QoR)

推荐系统中推荐者推荐能力的表示,依据推荐双方属性间的相关性求得其中属性包括双方的评价相似度、领域信任值和亲密程度以及推荐者的领域相关度。

2.1 用户评价相似度(user rating similarity)

文献[7,11]都将评价相似度和信任值结合作为选择推荐用户的依据。本文选用传统的皮尔逊(pearson)相关性度量公式计算评价相似度 $\text{Sim}(U, V)$,取值范围是 $[-1, 1]$,其中 1 表示完全正相关,0 表示无关,而-1 则表示完全负相关。 $\text{Sim}(U, V)$ 数值越大,说明两个用户的行为越相似。

用户间评价相似性的准确度在很大程度上依赖于用户间共同评分的服务数目,如果共同评分的服务较少,则这个相似性度量存在一定的偶然性。定义用户 U 和 V 之间共同评分的服务 $S' = S_U \cap S_V$,通过设定某个阈值 γ ,与用户 U 和 V 共同评分的服务数目 $|S'|$ 进行比较。

$$\text{Sim}'(U, V) = \frac{\min(|S'|, \gamma)}{\gamma} \times \text{Sim}(U, V) \quad (1)$$

从式(1)可以看出 $\frac{\min(|S'|, \gamma)}{\gamma} \leq 1$, 添加了影响性权重因子的 $\text{Sim}'(U, V)$ 的范围依然属于 $[0, 1]$ 。当用户间共同评分的数目大于阈值 γ 时,即 $\frac{\min(|S'|, \gamma)}{\gamma} = 1$,改良后的公式结果没有改变,而在共同评分数目较少的情况下,评价相似度值也相应减小。

2.2 领域信任值(domain trust value)

信任具有主观性、领域相关性、非对称性和一定的传递性^[13]。在推荐系统中,信任是指接受推荐者对提供推荐者特定行为的主观可能性预测,它是一种单向、相对、局限在一定范围内的主观反映^[14]。信任网络中计算信任的用户称为信任主体(trustor),被计算信任的用户称为信任客体(trustee)。用户间的信任包括他们之间的直接信任(direct trust)和来自其他用户的间接信任(indirect trust)。

之前的工作考虑了信任的主观性、非对称性和一定的传递性,体现在用户双方可以依据双方熟悉程度给予对方信任值,通过信任的传递从朋友的朋友那里获取推荐。但没有考虑信任的领域相关性,信任是与领域和上下文密切相关的,用户不可能在任何领域都信任另一用户,例如我们信任一个音乐家可以写出好的音乐,但不信任他可以修理电器。用户使用推荐系统通常希望获取的是某一类推荐,所以本文考虑信任的领域相关性,度量的是在特定领域的信任值。

在图 1 中, A 向 B 请求获取某种推荐,通常存在以下两种可能,一种是推荐结果由 B 自身给出,还有一种可能是 B 自身不知如何推荐,他从朋友 D 或 E 那里获得推荐后将其推荐给 A。社会学家将信任分成了 3 类:性情的(dispositional)、人际的(interpersonal)、客观的(impersonal)^[15]。受此启发,根据刚提到的两种可能情况,本文用户间信任包含二维信任关系:人际关系信任和领域信任。

定义 2(人际关系信任 T_S) 信任主体自身给出的与信

任客体间的信任表示的是信任主体对信任客体推荐的其他用户或服务的信任程度。

定义 3(领域信任 T_D) 依据信任主体与信任客体间在同一领域内的服务使用记录,度量出在特定领域的信任,表示的是信任主体对信任客体自身推荐的特定领域服务的信任程度。

人际关系信任 T_S 是在用户在与其他用户建立好友关系时自身给出的,信任值范围在 $[0, 1]$ 。将 T_S 分为 4 个级别:非常熟悉, $T_S \in (0.8, 1]$;较熟悉, $T_S \in (0.6, 0.8]$;普通, $T_S \in (0.3, 0.6]$;陌生, $T_S \in [0, 0.3]$ 。要计算领域信任值,首先得将用户使用过的服务分类,分类过程分为 3 个步骤:从用户使用过服务的 WSDL 文件中提取特征词,生成表示各个服务的特征向量;使用词义字典 WordNet 计算服务特征向量与领域本体归结成的中心向量间的距离;根据计算出的距离为服务选择合适的领域。在服务分类后便可以计算信任网络中的信任边在特定领域(domain)的 T_D 。将信任边两端用户最近使用的属于该领域的服务的 WSDL 文件合并成一个汇总 WSDL 文件来构造领域特征向量。在领域特征向量的基础上,结合向量空间模型。在向量空间模型中, D (Document)指被度量的文档,特征项(Term,用 T 表示)指出现在文档 D 中且能够代表该文档内容的基本语言单位,主要由词或短语构成,文本可以用特征项集表示为 $D(T_1, T_2, \dots, T_n)$ 。对含有 n 个特征项的文本而言,通常会给每个特征项赋予一定的权重来表示其重要程度,可通过 TF/IDF 算法算得,即 $D = D(T_1, W_1; T_2, W_2; \dots, T_n, W_n)$,称为文本 D 的向量表示,用户 U 与 V 的 D 领域向量表示为:

$$\langle U_domain \rangle = D_U = \{(T_1, W_{U,1}), (T_2, W_{U,2}), \dots, (T_m, W_{U,m})\}$$

$$\langle V_domain \rangle = D_V = \{(T_1, W_{V,1}), (T_2, W_{V,2}), \dots, (T_m, W_{V,m})\}$$

若词汇 T_k 没有出现在 U 或 V 的汇总 WSDL 中,则 $W_{U,k} = 0$ 或 $W_{V,k} = 0$ 。两个文本 D_U 和 D_V 之间的内容相关度 $\text{Sim}(D_U, D_V)$ 常用向量之间夹角的余弦值表示,如式(2)所示,计算出的值作为用户之间的领域信任值,即 $T_D(U, V) = \text{Sim}(D_U, D_V)$ 。

$$\text{Sim}(D_U, D_V) = \frac{\sum_{k=1}^m (W_{U,k} W_{V,k})}{\sqrt{(\sum_{k=1}^m W_{U,k}^2) \times (\sum_{k=1}^m W_{V,k}^2)}} \quad (2)$$

在计算出信任网络中信任边的 T_D 后,信任网络从一维变成二维。

计算任意两个用户 U 和 V 间领域信任值时存在两种情况, U 和 V 是直接关联的; U 可沿着信任网络中路径在规定的跳数内访问到 V 。第一种情况表示的是两者间的直接领域信任(Direct Domain Trust, $DDT(U, V)$),其值 $DDT(U, V) = T_D(U, V)$,第二种情况表示的是两者间的间接领域信任(Indirect Domain Trust, $IDT(U, V)$)。

2.2.1 计算间接领域信任 IDT

在信任网络中,当信任主体需要计算对信任客体的信任值时,若用户间没有直接信任关系,则来自熟悉人的推荐就非常重要了。本文采用文献[16]中提出的链式信任模型来计算用户间的间接领域信任值。该模型基于两个假设:如果一个

用户经过 6 步宽度优先搜索仍然无法到达另一个节点,就认为两个用户在信任网络中是不可达的;在信任网络中,信任传递的路径越长,其可信度就越低。该模型在信任计算过程中要用到包括传递函数、组合函数和融合函数在内的 3 种信任计算函数。传递函数用来计算没有直接关联的用户的聚合置信值,文中用符号 * 来指代传递函数;从起始用户到终点用户的路径可能不止一条,组合函数用于将不同路径上的聚合置信值进行组合,文中将多条路径上的聚合置信值加权平均作为双方面的组合置信值,每条路径上的权重和该条路径的长度成反比;融合函数用来计算出最终的融合信任值,如果有多个用户与所求信任用户直接关联,则对这多个用户的信任评价进行加权平均,权重是起始节点对每个目标节点的组合置信值。模型中提到的置信值表示的是用户对从朋友处传来的推荐或信息的信任程度,分析置信值会发现其含义与文中用户间人际关系信任值 T_S 大致相似,因此本文中用户间人际关系的信任值可比作模型中的置信值。

从信任主体 U 出发,按照广度优先搜索(Breadth_First Search, BFS)与信任客体 V 有直接关联的邻居用户(trustee neighbor) TN ,搜索过程中对 $T_S < 0.5$ 的信任边不予考虑, TN 的数值为 $|TN|$ 。 TN 中第 i 个用户表示为 $TN_i, 1 \leq i \leq |TN|$,从 U 到 TN_i 的路径集合为 $P(TN_i)$,其数值为 $|P(TN_i)|$,路径集合中第 j 个路径为 $P(TN_i)_j$ 。若从 U 到 TN_i 的第 j 条路径为 $p = \langle U, U_1, \dots, U_k \rangle$,则这条路径的聚合信任值(aggregated trust, AT)为 $AT(P(TN_i)_j) = T_S(U, U_1) \times \prod_{L=1}^{K-1} T_S(U_L, U_{L+1})$ 。组合函数中路径的权重公式为:

$$W_i = \frac{\frac{1}{D_i}}{\sum_{j=1}^n \frac{1}{D_j}} \quad (3)$$

其中, D_i 表示第 i 个路径的长度, n 表示路径的数目。据以上所述,用户间间接领域信任值的计算公式为:

$$IDT(U, V) = \frac{\sum_{i=1}^{|TN|} \sum_{j=1}^{|P(TN_i)_j|} W_j \times AT(P(TN_i)_j)}{\sum_{k=1}^{|TN|} \sum_{l=1}^{|P(TN_k)_l|} W_l \times AT(P(TN_k)_l)} \times DDT(TN_i, V) \quad (4)$$

2.2.2 计算综合领域信任值

领域信任值 $DT(U, V)$ 是用户间直接领域信任值和间接领域信任值的综合,可按式(5)计算:

$$DT(U, V) = \alpha DDT(U, V) + \beta IDT(U, V) \quad (5)$$

其中, α 和 β 为直接领域信任值和间接领域信任值的权重因子, $\alpha + \beta = 1$ 且 $0 \leq \alpha \leq 1, 0 \leq \beta \leq 1$ 。 α 和 β 的大小按照用户自身要求的信任严格程度设置,通常情况下 $\alpha > \beta$, 因为对用户自身来讲,直接交互经验比间接推荐得到的交互经验更可信。

2.2.3 信任值的更新

在推荐用户给推荐请求者推荐一系列服务后,两者间路径上信任边的信任值应予以更新,更新的依据是双方对推荐服务评分的差距。若两者间的评分差距小,则认为此推荐是好的,反之则认为是不好的。用户 V 在一交互过程中推荐 s 个服务, V 对这些服务的评分为 $R_V^{(1)}, R_V^{(2)}, \dots, R_V^{(s)}$, 用户 U 获取这些服务推荐,使用后给这些服务的评分为 $R_U^{(1)}, R_U^{(2)}, \dots, R_U^{(s)}$, 则此次交互的满意度为:

$$sat(U, V) = 0.5 - \frac{\sum_{k=1}^s |R_U^{(k)} - R_V^{(k)}|}{s \times Range} \quad (6)$$

其中, $Range$ 代表用户评分的范围值。计算得出的 $sat(U, V)$ 的范围在 $[-0.5, 0.5]$, 当值为 $[0, 0.5]$ 时说明此次推荐的效果是好的, 当值为 $[-0.5, 0]$ 时说明此次推荐效果是不好的, 根据推荐结果更新相应信任边的信任值。若推荐的传递路径长度为 1, 类似图 1 中 $A \leftarrow B$, 则更新双方信任边的 T_D 。若推荐的传递路径长度大于 1, 则更新传递路径中与 U 相连的信任边的 T_S 。这里使用文献[17]中提出的信任更新函数, 函数如下:

$$T_S^{t+1}(U, V) = (1 - sat(U, V)) \times T_S^t(U, V) + sat(U, V) \quad (7)$$

$$T_T^{t+1}(U, V) = (1 - sat(U, V)) \times T_T^t(U, V) + sat(U, V) \quad (8)$$

式中, t 代表时间。

设置时间间隔 T , 随着用户服务使用历史的更新, 每间隔 T , 重新度量直接关联用户间的 T_D , 与之前存储的 T_D 加权平均算得新的 T_D , 两个数据之间的权重比例视系统要求而定。

2.3 领域相关度(domain relative degree)

文献[18]中将用户领域相关度作为衡量推荐用户推荐能力的因素之一, 并证明了其在获取可信服务方面的有效性。例如我们需要获取 C 语言教科书的推荐, 大学里教 C 语言的老师的推荐要比同班同学的推荐有效得多。本文也将其引入作为影响推荐质量的因素之一。推荐用户的领域相关度是指推荐用户对某类服务的了解程度和关注程度。因此在推荐请求者需要某类服务的推荐时, 应增加这类服务的领域专家或对相关知识领域有深入了解的推荐用户的权重。由于验证用户领域相关度的方法比较复杂, 因此这里我们简单认为, 若用户对某类服务的评价次数较多, 则该用户为这类服务的领域相关用户。计算用户间领域信任值时已将服务进行了分类, 从而为辨别用户是否为领域相关用户以及获取相关度值创造了条件。假设推荐请求者希望被推荐的服务类型为 T , 推荐用户 V 历史评价信息中 T 类服务的评价总数为 N_V , 所有推荐用户评价 T 类服务的总数为 N , 则领域相关度(domain relative degree)计算公式为:

$$Drd(V, T) = N_V / N \quad (9)$$

2.4 亲密程度(social intimacy degree)

撇开信任度和评价相似度等决策性因素, 将任意推荐用户推荐的服务都同等对待显然是不合理的。在日常交往中, 人们往往对与自己越亲密的人越信任。例如我们想看电影, 向两个朋友获取推荐, 在他们其他属性情况同等的情况下, 我们肯定倾向于与自己关系更亲密的那个朋友。推荐请求者与推荐用户的亲密程度越高, 则对该推荐用户的信任度越高, 反之亦然^[9]。因此, 本文将用户之间的亲密程度作为影响推荐质量的属性, 对与推荐请求者亲密程度大的推荐用户, 应增加其推荐权重。准确度量用户亲密程度比较困难, 为了便于实现, 本文简单地认为, 推荐请求者与某个推荐用户的交互次数越多, 则他们之间的亲密程度越高。假设推荐请求者 U 与其他用户交互的总数为 $I(all)$, 与用户 V 的交互次数为 $I(U, V)$, 则 U 和 V 之间的亲密程度计算公式为:

$$Sid(U, V) = I(U, V) / I(all) \quad (10)$$

2.5 推荐质量(quality of recommendation)

在服务选择领域, 服务请求者将服务的 QoS 值, 如响应时间、可靠性、安全性等, 作为选择标准来进行服务选择。同理, 在服务推荐领域, 推荐请求者将网络中其他用户的 QoR 作为选择标准来选择推荐用户。QoR 属性包括上面提到的

用户评价相似度、领域信任值、领域相关度、亲密程度。对推荐用户的各个 QoR 属性赋予相应的权重,可以度量每个用户的 QoR 值,本文使用信息熵来确定属性的权重比例。信息熵是由香农(Shannon)将热力学熵引入信息论而提出的,其为不确定方法的一个重要概念,常被用于较粗略地给出不确定性的度量。在事件发生之前,信息熵是结果不确定性的量度,在事件发生之后,它是事件中所得信息的量度(信息量)。因此,事件的信息熵,是一个事件的不确定性或信息量的度量,也可以理解为包含在这个事件本身中的关于它自己的信息,因为事件发生后结果就完全确定了^[20]。属性的信息熵计算公式为:

$$H(attri) = -attri \times \log attri - (1 - attri) \log(1 - attri) \quad (11)$$

其中, $attri$ 代表属性的值。 $H(attri)$ 的值越大,说明 $attri$ 的平均不确定性越大。由式(12)可以看出 $0 \leq H(attri) \leq 1$,且熵函数以 $attri = 0.5$ 为轴对称分布,说明 $attri$ 在区间 $[0, 0.5]$ 和在区间 $[0.5, 1]$ 可能发生的不确定性程度大小相等。由于熵函数的对称性,我们不能唯一判断出事件可信的不确定性程度。针对这一局限,我们对原公式做了修改。

$$V_m = \begin{cases} 1 - \frac{1}{\log 5} H(attri) & , H(attri) > 0.5 \\ 0.5 - \frac{1}{\log 5} H(attri) & , H(attri) \leq 0.5 \end{cases} \quad (12)$$

各属性权重计算公式为:

$$w_m = V_m / \sum_{m=1}^4 V_m \quad (13)$$

计算出各属性的权重后,就可以计算出用户 U 的 QoR 值了,定义为:

$$Qor(U) = \sum_{m=1}^4 W_m \times attri_m \quad (14)$$

3 基于推荐质量的信任感知推荐系统(QoRBTARS)

根据上节计算的推荐质量,提出一种基于推荐质量的服务推荐方法。从推荐请求者开始用 BFS 搜索最大信任传递距离内的用户,利用式(15)计算出他们的 QoR 值,挑选出 QoR 值大于初始值 $Qor(threshold)$ 的用户,组成信任推荐用户集(Trustworthy Recommender Set), $Qor(threshold)$ 的值根据用户对推荐用户的要求程度设置。通过聚集信任推荐用户对某类服务的评分来预测源用户对这类服务的评分。计算公式如下:

$$\hat{P}_{r,i} = \bar{r}_r + \frac{\sum_{v \in T_r} Qor_{r,v} \times (r_{v,i} - \bar{r}_v)}{\sum_{v \in T_r} Qor_{r,v}} \quad (15)$$

其中, T_r 表示为推荐请求者的信任推荐用户集, $Qor_{r,v}$ 表示用户 V 相对于推荐请求者的推荐质量, $r_{v,i}$ 表示用户 V 对服务 i 的评分, \bar{r}_v 表示用户 V 的平均评分。

具体的算法过程如下:

算法 1 基于推荐质量的服务推荐方法

Input: 推荐请求者 S , 用户服务评分矩阵 $R_{s \times t}$, 信任矩阵(trust matrix), 信任边人际关系信任值 T_s , 推荐用户集人数 MAX_{RU} , Qor 临界值 $threshold_{qor}$, 希望被推荐的服务类型 T , 信任传递距离 L 。

1. Compute T_D of trust matrix for type T
2. User $\square userSet = BFS(L)$;
3. For(user; userSet) {

```

compute Sim(S, user), DT(S, user), Drd(S, user), Sid(S, user);
compute Qor(user);
If(qor(user) > qor(threshold)) {
    If(++count >= MAXRU);
        Break;
    }
Else continue;
}

```

4. Predict rating for unrated service of S ;
 5. Return highest top k services;
 6. Update relevant trust;
- Output K services

上述算法中,第 1 部分度量类型 T 的领域信任值,第 2 部分采用广度优先算法搜索用户,第 3 部分筛选 QoR 满足要求的用户形成推荐用户集,第 4 部分预测请求者对未使用服务的评分,第 5 部分返回推荐的服务,第 6 部分更新信任值。因为方法中要计算推荐用户的领域相关度和与推荐请求者的亲密程度,所以要搜索出信任传递距离内的所有邻居用户。搜索邻居用户的时间复杂度为 $O(kd)$,其中 k 表示信任网络中节点的平均出度, d 表示信任传播的距离。相比文献[9]中搜索预定数目信任用户的方法,本文搜索邻居用户的时间复杂度要高得多。另外,相比已有文献中的方法,本文需要将用户使用过的服务进行分类,并计算和储存不同领域的信任值,这需要一些额外时间和空间开销。

算法的体系结构如图 3 所示。

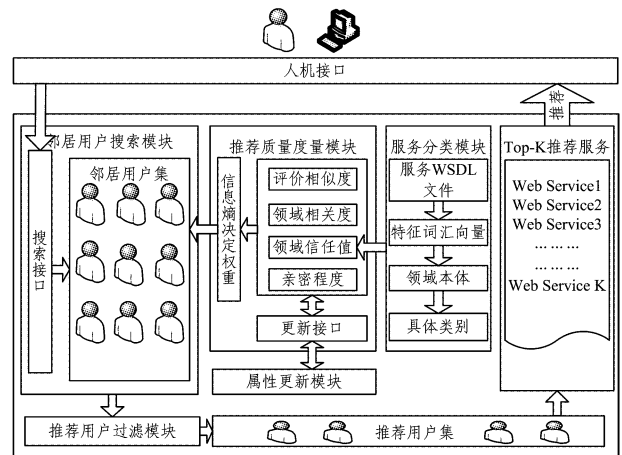


图 3 QoRBTARS 体系结构

4 仿真实验及结果分析

4.1 实验准备

最适合于引入信任的推荐系统进行实验的数据集是 FilmTrust,但 FilmTrust 数据集没有公开,因此本文采用 Epinions 数据集。Epinions 数据集是采集于 Epinions 网站的真实数据,网站中的用户不仅可以给各种商品(如书籍、衣服等)进行评论和打分(最高为 5,最低为 1),还可以参照其他用户的评论来给出信任评估。该数据集中包含两个文件,第一个为用户评分文件,包含 49289 个用户对 139738 个商品的 664825 个评分。另一个为信任网络文件,包含了 49289 个用户间 487181 个信任关系。由于数据集中数据规模超过了实验用计算机的计算和存储能力,因此本文抽取评分分布与全体用户评分分布大致一致的用户 500 名、评分人数分布与全

部商品评分人数分布大致一致的商品 2500 个作为实验数据集。将实验数据集的 80% 设置为训练数据,余下的 20% 为测试数据。但 Epinions 数据集中用户间信任关系是布尔型的,且用户只有商品及评分记录,并没有服务调用记录,所以这个数据集并不能直接用于本文的信任值计算。因此为了验证本文方法的有效性,这里人为给信任边添加人际关系信任值 T_s , T_s 变量的概率密度函数应以 $X=0.5$ 为对称轴。通过网络爬虫或从 Web 服务搜索引擎(如 Binding Point、Grand Central、Seekda、Web Service List 和 Web Service Supermarket)那里搜集 2500 个 Web 服务。先按 2.2 节中提到的服务分类方法将服务分类,以评分记录中商品种类多少与比例大小为基准,将这些服务赋给用户作为他们的服务历史记录。

4.2 实验评价指标

(1) 精确度

精确度是衡量一个推荐系统推荐能力的重要指标,本文采用推荐系统中最常用的平均绝对偏差 MAE (Mean Absolute Error) 作为精确度指标。MAE 通过计算预测的用户服务评分与实际的客户服务之间的偏差来度量预测的准确性,MAE 越小,精确度越高。

(2) 冷启动用户的推荐

传统协同过滤推荐系统不能解决为冷启动用户推荐的问题,而 Epinions 数据集中评分记录在两个以内的用户数占到整个用户群体的 42.2%。因而测量冷启动用户的召回率 (Recall) 是检验引入信任的基于协同过滤推荐系统能力的重要指标。召回率指正确推荐的项目数占总共需要被荐项目数的百分比。

(3) 评分覆盖率

在数据稀疏的情况下,评分覆盖率是衡量推荐系统能力的重要指标之一。评分覆盖率 (Rate Coverage) 指的是推荐系统能够预测的用户对项目的评分占有所有评分的百分比。

4.3 仿真实验与结果分析

实验将本文推荐算法与文献[7]的 TPCF 和文献[10]的 T-index 进行比较,以验证本文所提方法提高推荐系统在评分数据稀疏情况下的推荐能力和为冷启动用户有效推荐方面的可行性。




图 4 不同推荐用户个数 MAE 比较

实验 1 图 4 反映了 3 个方法系统在不同推荐用户个数下的精确度情况。可以看出,开始 TPCF 方法随着推荐用户个数的增加,MAE 迅速下降,后来趋于平缓。TPCF 方法推荐用户个数的临界点在 25 左右,当推荐用户人数增加到 25 左右时 MAE 达到最低,之后增加推荐用户个数,MAE 反而上升。这是因为在临界点后增加的推荐用户与推荐请求者间的信任值和评价相似度已经变得较低,而它们的推荐影响了整个推荐系统的精度。而 T-index 方法只考虑了信任值没有考虑评价相似度,所以推荐用户人数在 28 之前,其 MAE 一

直高于 TPCF 方法,但此方法打破了信任传递距离的限制,能选择到一些在指定信任传递距离内无法发现却有很高信誉的推荐用户,因此随着推荐人数增加,MAE 稳步下降。本文方法相比这两个方法,用户间信任表达更精确,因此 MAE 较低。同时,本文方法没有出现推荐人数增加而 MAE 上升的现象,这是因为考虑了领域相关度和亲密程度两个属性对推荐能力的影响,在信任值和评价相似度较低的时候,对那些经常接触的和领域内有深入了解的用户赋予了更大的权重。




图 5 冷启动用户召回率比较

实验 2 图 5 反映了冷启动用户在 3 种方法下的召回率比较情况。从测试集中选出评分数目为零、一个或两个的用户作为冷启动用户并将他们分类。从图中可以看出,本文方法对召回率的提升很明显。在 TPCF 中冷启动用户由于极度缺乏评分数据导致很难找到兴趣爱好相似的用户,基本只能靠信任值筛选出推荐用户集,信任值的大小并不能代表兴趣爱好相似程度,所以召回率一直处在较低的水平。随着评分数目的增加,评分相似度发挥效用,召回率稍微提升。而评分数据的多少对 T-index 方法选择推荐用户并没有直接的影响,所以其召回率基本维持在 20% 左右。本文方法可请求推荐某一类服务,这有效地缩小了推荐服务的范围,另外,由于评分数据的稀疏,给了其他属性如领域相关度更大的权重,以更容易找到在这一类领域有深入了解的用户。




图 6 不同推荐用户个数评分覆盖率比较

实验 3 图 6 反映了 3 个方法在不同推荐用户个数下评分覆盖率的情况。总的来说,本文方法比 TPCF 要好,但相比 T-index 要差些。相比 TPCF,本文方法能选择到那些在相关领域有影响的,这些用户往往有着相对较高的评分比例,所以整个实验过程中本文方法的评分覆盖率要比 TPCF 高。当推荐人数较少时,推荐用户推荐质量整体较高,评分覆盖率较 T-index 高。不过本文方法跟 TPCF 一样有信任传递距离的限制,随着推荐用户人数的增加,推荐用户整体推荐质量下降。而 T-index 方法能发现限制距离外 T-index 值大的用户,这些用户通常被很多用户信任。而推荐系统中,一个用户能被很多用户信任,多数是因为其高效的推荐能力。要想向多个用户推荐满意的服务,其自身使用的服务数目必然相当可观。所以当推荐人数较多时,本文的评分覆盖率较 T-index 低。

(下转第 135 页)

- [4] Appukkutty K, Ammar H H, Popstajanova K G. Software requirement risk assessment using UML[C]//3rd ACS/IEEE International Conference on Computer Systems and Applications, 2005. Cairo, Egypt, 2005; 615-618
- [5] 闫栋, 祁国宁. 大规模软件系统的无标度特性与演化模型[J]. 物理学报, 2006, 55(8): 3799-3806
- [6] 何克清, 李兵, 马于涛. 软件网络[M]. 北京: 科学出版社, 2008
- [7] 李兵, 马于涛, 刘婧, 等. 软件系统的复杂网络研究[J]. 力学进展, 2006, 38(6): 805-813
- [8] Gilliam D P, Powell J D, Kelly J C. Reducing Software Security Risk through an Integrated Approach[C]//Presented at the The 26th Annual NASA Goddard Software Engineering Workshop, 2001
- [9] Yacoub S M, Ammar H H. A methodology for architecture-level reliability risk analysis[J]. IEEE Transactions on Software Engineering, 2002, 28(6): 529-547
- [10] 郑明辉, 周慧华, 马光致. 基于 UML 需求分析模型的软件规模评估方法[J]. 计算机应用与软件, 2004, 21(3): 23-25
- [11] Munson J, Khoshgoftaar T. Software Metrics for Reliability Assessment[M]. McGraw-Hill, USA, 1996
- [12] Jian X, Han Y, Qianmu L. A methodology for software reliability risk assessment[J]. Journal of Convergence Information Technology, 2011, 6(4): 188-200
- [13] Yacoub S M, Ammar H H, Robinson T. Methodology for architectural-level risk assessment using dynamic metrics[C]//11th International Symposium on Software Reliability Engineering (ISSRE 2000). San Jose, CA, USA, 2000; 210-221
- [14] 刘正高. 软件失效模式、影响及危害性分析问题探讨[J]. 电子产品可靠性与环境试验, 2000, 1: 26-29
- [15] Wang B, Wang L. Analysis of defects propagation in software system based on weighted software networks[J]. Journal of Convergence Information Technology, 2012, 7(17): 63-77
- [16] Fenton N E, Ohlsson N. Quantitative Analysis of Faults and Failures in a Complex Software System[J]. Proceeding(s) of the IEEE Transactions on Software Engineering, 2000, 26(8): 797-813
- [17] McCabe T. A Complexity Metrics [J]. IEEE Transactions on Software Engineering, 1976, 2(4): 308-320
- [18] 刘海, 郝克刚. 软件缺陷原因分析方法[J]. 计算机科学, 2009, 36(1): 242-244

(上接第 124 页)

结束语 本文提出基于推荐质量的信任感知推荐系统, 用以综合评价相似度、领域信任度、亲密程度和领域相关度, 求用户的推荐质量, 并以此为基准选择推荐用户完成推荐。仿真表明本文方法能提高推荐系统在数据稀疏状况下的精确度以及冷启动用户的召回率, 但由于仍然存在信任传递距离的限制, 在解决评分覆盖率方面效果不是特别突出, 同时也存在着时间和空间复杂度较高的问题。在未来的工作中可以应用聚类算法先将服务使用偏好相似的用户聚类, 缩小搜索的范围, 以便能够高效地搜索推荐质量高的推荐用户, 有效降低方法的时间复杂度, 同时摆脱信任传递距离的限制。

参 考 文 献

- [1] Zhang L-J, Zhang J, Cai H. Services computing[M]. Springer and Tsinghua University Press, 2007
- [2] Kang Guo-sheng. AWSR: Active Web Service Recommendation Based on Usage History[C]//19th International Conference on Web Services(ICWS). 2012; 186-193
- [3] Sarwar B, Karypis G, Konstan J, et al. Analysis of recommendation algorithms for e-commerce[C]//Presented at the Proceedings of the 2nd ACM Conference on Electronic Commerce, Minneapolis, Minnesota, United States, 2000
- [4] Sinha R, Swearingen K. Comparing recommendations made by online systems and friends[C]//Proceedings of the DELOS-NSF Workshop on Personalization and Recommender Systems in Digital Libraries. Puerto Vallarta, Mexico, 2001
- [5] Crandall D, Cosley D, Huttenlocher D, et al. Feedback effects between similarity and social influence in online communities [C]//KDD 2008, 2008; 160-168
- [6] Massa P, Bhattacharjee B. Using trust in recommender systems: An experimental analysis[C]//Proceedings of iTrust2004 International Conference, 2004; 221-235
- [7] Chen Xiao-cheng, Liu Run-jia, Chang Hui-you. Research of collaborative filtering recommendation algorithm based on trust propagation model [C] // Computer Application and System Modeling (ICASM). Taiyuan, 2010
- [8] Jamali M, Ester M. TrustWalker: A Random Walk Model for Combining Trust-based and Item-based Recommendation[C]//KDD 2009. Paris, France, 2009
- [9] Jamali M, Ester M. Using a Trust Network to Improve Top-N Recommendation [C]//Proceedings of the third ACM Conference on Recommender Systems, 2009; 181-188
- [10] Zarghami A, Fazeli S, Dokoochaki N, et al. Social Trust-aware Recommendation System: A T-Index Approach [C]//Proceedings of the IEEE/WIC/ACM International Joint Conference on Web Intelligence and Intelligent Agent Technology, 2009; 85-90
- [11] Gao Yuan-liang, Xu Bo-yi, Cai Hong-ming. Information Recommendation Method Research Based on Trust Network and Collaborative Filtering[C]//IEEE 8th International Conference on e-Business Engineering(ICEBE). 2011; 386-391
- [12] Bedi P, Sharma R. Trust based recommender system using ant colony for trust computation[J]. Expert Systems with Applications, 2012, 39(1): 1183-1190
- [13] 张宇, 陈华钧, 姜晓红, 等. 电子商务系统信任管理研究综述[J]. 电子学报, 2008, 36(10): 2011-2020
- [14] 蔡浩, 贾宇波, 黄成伟. 结合用户信任模型的协同过滤推荐方法研究[J]. 计算机工程与应用, 2010, 46(35): 148-151
- [15] Abdul-Rahman A, Hailes S. Supporting trust in virtual communities[C]//Proceedings of the 33rd Hawaii International Conference on System Sciences, USA, 2000
- [16] Zhang Yu, Chen Hua-jun, Wu Zhao-hui, et al. A Reputation-Chain Trust Model for the Semantic Web[C]//IEEE 20th International Conference on Advanced Information Networking and Applications, 2006; 719-723
- [17] Moghaddam S, Jamali M, Ester M, et al. FeedbackTrust: Using Feedback Effects in Trust-based Recommendation Systems[C]//Proceedings of the Third ACM Conference on Recommender Systems, 2009; 269-272
- [18] 朱锐, 王怀民, 冯大为. 基于偏好推荐的可信服务选择[J]. 软件学报, 2011, 22(5): 852-864
- [19] Miller R, Perlman D, Brehm S. Intimate Relationships(4th edition)[M]. McGraw-Hill College, 2007
- [20] Yulmetyev R M, Emelyanova N A, Cafarov F M. Dynamical Shannon entropy and information Tsallis entropy in complex systems[J]. Physica A, 2004, 341(11): 649-676