

基于 SOM 神经网络的服务质量预测^{*}



张以文^{1,2}, 项涛², 郭星², 贾兆红^{1,2}, 何强³

¹(计算智能与信号处理教育部重点实验室(安徽大学),安徽 合肥 230039)

²(安徽大学 计算机科学与技术学院,安徽 合肥 230039)

³(School of Information Technology, Swinburne University of Technology, Melbourne VIC3122, Australia)

通讯作者: 张以文, E-mail: zhangyiwen@ahu.edu.cn

摘要: 服务质量预测在服务计算领域中是一个热点研究问题。在历史 QoS 数据稀疏的情况下,设计一个满足用户个性化需求的服务质量预测方法成为一项挑战。为了解决这一挑战问题,提出一种基于 SOM 神经网络的服务质量预测方法 SOMQP。首先,基于历史 QoS 数据,应用 SOM 神经网络算法分别对用户和服务进行聚类,得到用户关系矩阵和服务关系矩阵;进而,综合考虑用户信誉和服务关联性,采用一种新的 Top- k 选择机制获得相似用户和相似服务;最后,采用基于用户和基于项目的混合策略对缺失的 QoS 值进行预测。在真实的数据集 WS-Dream 上进行了大量实验,结果表明,与经典的 CF 算法和 K-means 算法相比,该方法在较大程度上提高了 QoS 的预测精度。

关键词: 质量预测;SOM;神经网络;K-means

中图法分类号: TP311

中文引用格式: 张以文,项涛,郭星,贾兆红,何强.基于 SOM 神经网络的服务质量预测.软件学报,2018,29(11):3388–3399.
<http://www.jos.org.cn/1000-9825/5474.htm>

英文引用格式: Zhang YW, Xiang T, Guo X, Jia ZH, He Q. Quality prediction for services based on som neural network. Ruan Jian Xue Bao/Journal of Software, 2018,29(11):3388–3399 (in Chinese). <http://www.jos.org.cn/1000-9825/5474.htm>

Quality Prediction for Services Based on SOM Neural Network

ZHANG Yi-Wen^{1,2}, XIANG Tao², GUO Xing², JIA Zhao-Hong^{1,2}, HE Qiang³

¹(Key Laboratory of Intelligent Computing and Signal Processing (Anhui University), Ministry of Education, Hefei 230039, China)

²(School of Computer Science and Technology, Anhui University, Hefei 230039, China)

³(School of Information Technology, Swinburne University of Technology, Melbourne VIC3122, Australia)

Abstract: Quality prediction for services is a hot research topic for service recommendation and composition. It's a challenge to design an accurate quality prediction approach to meet the user's personalized needs due to the sparsity of QoS historical data. In order to solve the challenging problem, this paper proposes a SOM neural network based service quality prediction approach (SOMQP). First, based on historical QoS data, the new approach clusters on users and services respectively by applying SOM neural network algorithm, and then a new top- k selection mechanism is adopted to obtain similar users and similar services based on the comprehensive consideration of user reputation and service relevance. Finally, a hybrid user-based and item-based strategy is used to predict the missing QoS value. A set of comprehensive experiments are conducted on the real Web service dataset WS-Dream, the results indicate that compared with the classical CF and K-means methods, the presented approach achieves higher QoS prediction accuracy.

* 基金项目: 国家科技支撑计划(2015BAK24B01); 国家自然科学基金(71601001, 61872002); 安徽省自然科学基金(1808085MF197)

Foundation item: National Key Technology R&D Program (2015BAK24B01); National Natural Science Foundation of China (71601001, 61872002); Natural Science Foundation of Anhui Province (1808085MF197)

本文由面向智能制造的业务过程管理与服务技术专题特约编辑王建民教授、刘建勋教授推荐。

收稿时间: 2017-07-14; 修改时间: 2017-09-16; 采用时间: 2017-11-14; jos 在线出版时间: 2017-12-06

CNKI 网络优先出版: 2017-12-06 15:37:16, <http://kns.cnki.net/kcms/detail/11.2560.TP.20171206.1536.021.html>

Key words: quality prediction; SOM; neural network; K-means

随着云计算、大数据、面向服务架构(SOA)、物联网技术^[1]的发展,以产品服务系统、云制造等为代表的面向服务的智能制造服务生态系统应运而生。如何从大规模的功能属性相同而非功能属性不同的候选服务中,为用户有效地推荐满足其个性化需求的服务,已成为一项极具挑战性的研究课题。服务质量(quality-of-service,简称 QoS)通常用于表示服务的非功能属性,如响应时间、代价和吞吐量等,已广泛应用于基于业务工作流的服务组合^[2,3]、服务选择^[4,5]和服务推荐系统^[6-8]中。工作流作为一种面向过程建模和管理的核心技术,在实现面向业务流程的应用集成方面表现出强大的应用能力,利用工作流组织协同相关服务,实现一定的增值业务功能,已成为一种高效利用众多服务的可行方式。然而,随着服务的日益丰富,每个工作流活动可能存在众多功能属性相同而非功能属性不同的候选服务集,用户不可能通过调用所有服务来获取每个工作流活动中服务的 QoS 值,这就导致用户-服务矩阵非常稀疏。为此,推荐系统需要在 QoS 信息缺失的情况下,为用户推荐满足其个性化需求的服务。假设用户 u 需要定制化某个产品,服务平台有 4 个服务 s_1, s_2, s_3 和 s_4 满足其功能性需求。用户 u 已经调用过服务 s_1, s_2, s_3 ,但是没有调用过服务 s_4 ,因此推荐系统无法为用户 u 推荐 QoS 最优的服务。为解决这一问题,就需要预测用户 u 调用服务 s_4 的 QoS 值。因此,服务质量预测在面向服务的个性化推荐系统中扮演着重要的角色。

目前,服务质量预测方法的研究主要是基于协同过滤技术^[9-12],包括基于记忆和基于模型的协同过滤方法。基于记忆的协同过滤预测的主要过程是:首先,通过皮尔逊相关系数(PCC)计算相似度来寻找相似用户或相似服务;然后,使用相似用户或相似服务的 QoS 值对缺失值进行预测。基于模型的协同过滤预测方法需要根据训练集数据和机器学习方法得到一个训练模型,然后通过相似邻居的服务质量值来预测目标服务的缺失值。虽然现在很多工作都在研究基于协同过滤的服务质量预测方法,但依然存在一些重要的问题。

- (1) 数据稀疏性:如今,服务数爆炸式增长,而由于一些条件的限制,用户不可能调用所有服务去获取每个服务的 QoS 评价值,这也就导致了用户-信息矩阵中大部分数据的缺失。用户-信息矩阵的数据稀疏,使得传统的协同过滤算法很难通过计算相似度寻找相似用户或相似服务,因此,QoS 预测精度也会受到限制。
- (2) 用户信誉:在对服务评价过程中,会有一些用户对一些服务进行恶意的评价,即对不好的服务给出很高的评分或对好的服务给出很低的评分,这些用户的评价影响预测精度。因此,在 QoS 预测过程中减少用户恶意评价的影响已然变得很重要,应当充分利用信誉良好用户的评价信息来提高预测精度。
- (3) 服务关联性:同样地,在用户对服务的评价过程中,如果两个服务被多个用户调用后获得相同或相似的服务评价,那么可以认为这两个服务之间具有较高的关联性。因此,如果在预测的过程中考虑关联性比较高的服务,充分利用服务之间的关联信息,可以进一步提高预测精度。

下面以 9 个用户调用 10 个服务的情况为例,其调用关系如图 1 所示。

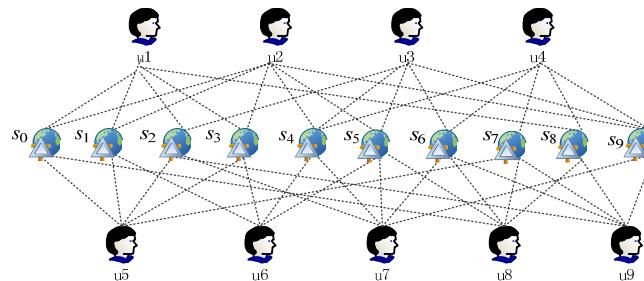


Fig.1 An example of users invoking services in service-oriented environment

图 1 面向服务环境中用户调用服务的示例

由于用户不可能调用所有的服务并给与 QoS 评价,因此生成的用户-服务矩阵是一个稀疏矩阵,如图 2 所示。

	s_0	s_1	s_2	s_3	s_4	s_5	s_6	s_7	s_8	s_9
u_1	4.8	4.2	4.0	3.9						4.6
u_2	4.6	4.5		4.2	3.4	2.8				3.5
u_3			4.9		4.1	2.6	3.0			3.8
u_4				3.3		4.7	4.2	4.5	3.0	
u_5	3.2	4.4	4.7	2.8				4.3		
u_6				3.4	4.3	4.0			3.6	
u_7		1.1	3.9		4.2	3.9	4.5			2.8
u_8	3.4					2.7	3.2	4.8	3.9	
u_9			3.8			4.9	2.8	4.0	3.9	

Fig.2 A rating matrix of users invoking services

图 2 用户调用服务的评价矩阵

对于图 2 中用户-服务矩阵的缺失值,如果使用传统的基于协同过滤的 QoS 预测方法,首先通过 PCC 来计算相似度,然后根据相似度去寻找相似用户或相似服务,最后根据相似用户或相似服务的评价值来预测缺失值。这种方法实现起来简单,但是当矩阵很稀疏时,很难通过少量的 QoS 值来计算相似度,这会导致预测精度降低。并且这种方法没有充分考虑用户信誉和服务关联性。

为解决这一问题,可使用聚类算法对用户和服务进行聚类去寻找相似用户和相似服务^[13-15],这样,在服务选择和推荐时,如果两个用户对相同的服务有相似的服务质量评价,则认为这两个用户是相似的;同样地,如果两个服务被相同的用户调用后有相似的服务质量评价,则认为这两个服务也是相似的。目前已有研究使用 K-means 聚类算法来解决这一问题,但是该算法初始点的选取会严重影响聚类效果^[14]。

基于以上分析,本文提出了基于 SOM 神经网络的服务质量预测方法 SOMQP。通过引入具有拓扑结构的领域函数,将所有的神经元都置于一个根据先验知识而事先确定的拓扑结构,可以达到较为稳定的聚类结果,从而保证 QoS 预测精度的稳定性。实验结果表明,SOMQP 方法较大幅度上提高了预测精度。本文的主要贡献如下。

- (1) 根据历史 QoS 值分别对用户和服务使用 SOM 神经网络算法进行聚类,得到用户关系矩阵和服务关系矩阵,分别记录不同的用户或服务被聚类到同一个簇中的次数。
- (2) 提出一种新的 Top- k 选择机制,具体而言,首先,基于用户关系矩阵寻找恶意评价用户,减少恶意评价用户对预测精度的影响;其次,基于服务关系矩阵寻找相关性服务,从而获得相似用户和相似服务,即对用户关系矩阵和服务关系矩阵的每行元素进行从大到小排序,前 k 个即为目标用户或目标服务的相似用户或相似服务。
- (3) 在真实数据集 WS-Dream 上进行了大量的实验,实验结果表明,与经典的 CF 算法、基于改进的 PCC 预测算法和 K-means 聚类算法相比,本文方法的 QoS 预测精度提高了 34.9%,29.5% 和 4.3%。

本文第 1 节介绍服务质量预测的相关工作。第 2 节详细解释 SOMQP 算法的实现过程。第 3 节是实验结果与分析。第 4 节对全文进行总结。

1 相关工作

在服务选择和服务推荐领域,服务的 QoS 预测已经成为一个热点问题,在所有的预测方法中,协同过滤的方法已经广泛地应用到商业推荐系统中。协同过滤算法主要分为两类:基于模型的和基于记忆的。Sarwar 等人^[16]提出了基于服务的历史数据去预测缺失的 QoS。Zheng 等人^[17]结合基于用户和基于服务提出了一种混合的预测方法。这些方法主要通过 PCC 计算来寻找相似用户或相似服务,进而预测缺失值,虽然简单易于实现,但用户-服务矩阵很大时,很难扩展。

为进一步提高传统的协同过滤算法的有效性,Zhao 等人^[18]提出一种基于时间段的 QoS 预测方法,对历史数据在时间维度和空间维度上寻找数据特征,结合基于用户的协同过滤方法和 ARMA 模型,对未知的 QoS 数据进行预测。Chen 等人^[19]提出一种基于概率模型的 QoS 预测方法,该方法分别使用概率密度函数和概率分布函数对连续和离散的 QoS 值进行建模,设计在不同时期选择不同服务的预测模型。Lo 等人^[20]提出使用矩阵分解技术对缺失 QoS 值预测。这些方法一定程度上提高了预测精度,但都没有考虑恶意评价用户对预测精度的影响以及服

务之间的关联性.

为此,相关研究提出了聚类方法来解决这个问题.Zhu 等人^[21]为服务推荐提出一个基于聚类的 QoS 预测框架,通过获取真实的 QoS 数据,使用聚类技术提高预测精度.但该方法需要获取实时的 QoS 数据,不具有通用性.Chen 等人^[22]提出一种基于用户 QoS 的聚类方法,该方法对服务进行聚类,然后在聚类的基础上计算用户之间的相似度,进而减少执行时间,但没有对用户进行聚类考虑用户之间关系.Zhang 等人^[23]提出一个基于模糊聚类的 QoS 预测方法,该方法是在计算用户之间相似度的基础上结合传统模糊聚类,但聚类时初始点的选取会影响预测精度.为此,本文提出一种基于 SOM 神经网络^[24,25]的服务质量预测方法 SOMQP,分别对用户和服务进行聚类,得到用户关系矩阵和服务关系矩阵,在用户关系矩阵的基础上寻找恶意评价用户,减少恶意评价用户对预测精度的影响,并在服务关系矩阵的基础上考虑服务关联性;然后,采用一种新的 Top-k 选择机制获得相似用户和相似服务,最后对缺失值进行预测.

2 服务质量预测算法及过程

在服务推荐系统中,由于用户不可能调用所有服务以获得 QoS 评价值,导致历史 QoS 数据的稀疏性,因此要设计一个满足用户个性化需求的 QoS 预测方法成为一个很大的挑战.为解决这一挑战问题,本文提出一个基于 SOM 算法的预测框架,如图 3 所示.主要包括以下 3 个过程:(1) SOM 聚类模块中,根据服务历史 QoS 值分别对用户和服务进行聚类,得到用户关系矩阵和服务关系矩阵;(2) Top-k 机制模块中,对用户关系矩阵和服务关系矩阵采用一种 Top-k 选择机制得到目标用户和目标服务的相似用户集和相似服务集;(3) 基于相似用户和相似服务的混合策略对缺失 QoS 值进行预测.

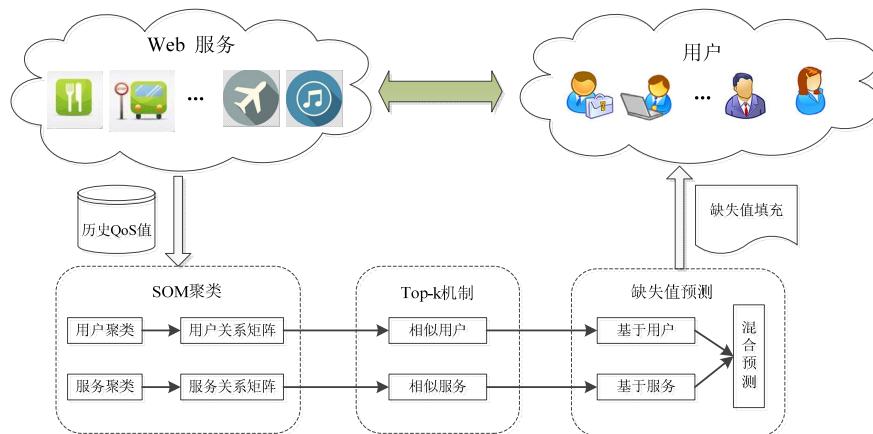


Fig.3 Quality prediction framework for services

图 3 服务质量预测框架

2.1 SOM聚类

SOM(self-organizing map)神经网络是 Kohonen 教授提出的一种无监督学习算法^[24],是人工神经网络的重要分支之一,它可以通过学习来提取一组数据中的内在规律,按离散时间方式进行分类.并且可以把任意高维的输入映射到低维空间,使得输入数据内部的相似性质表现为空间上近邻的特征映射.这样就可以在输出层映射成一维或二维的离散图形,并保持其拓扑结构不变.如图 4 所示,SOM 是由输入层和竞争层组成的神经网络,输入层是一维的 n 个节点的神经元,竞争层是由 $M=m^2$ 个节点组成的二维神经元的节点矩阵,并且输入层的神经元和竞争层的神经元都有权值连接.

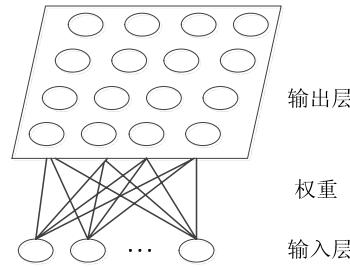


Fig.4 Two-Dimensional model of SOM

图 4 SOM 的二维模型

设输入层 $x=(x_1, x_2, \dots, x_n)$ 是一个 n 维向量,输出层是一个有 M 个节点的二维网络, w_{ij} 是第 i 个输入神经元节点与第 j 个输出神经元节点之间的权值,该算法的训练过程.

- (1) 将连接权重、学习效率以及邻域初始化, w_{ij} 选择[0,1]之间的随机值,并且所有的值互不相同.
- (2) 将样本以及连接向量进行归一化;归一化之后,计算输入向量在到输出节点的距离 $d(x, w)$:

$$d(x, w) = \sqrt{\sum_{i=1}^n (x_i - w_{ij})^2} \quad (1)$$

- (3) 从上面计算得到的距离节点中选择最小的 $d(x, w)$ 为最佳匹配节点,即神经元 i 为获胜神经元.
- (4) 调整权值向量的更新公式:

$$w_{ij}(t+1) = w_{ij}(t) + \alpha(t) h(t) [x(t) - w_{ij}(t)] \quad (2)$$

其中, $\alpha(t)$ 是学习效率, $0 < \alpha(t) < 1$, 且随着时间 t 而减少; $h(t)$ 是邻域内第 i 个神经元和获胜神经元 j 之间的拓扑距离的函数.

- (5) 重复上述步骤,直到对所有样本学习后,学习效率 $\alpha(t) < \alpha_{\min}$ 时结束.

根据上述聚类原理,对于调用同一个服务的不同用户,如果他们评价服务的 QoS 值相同或相似,那么对用户进行聚类时,它们被聚到同一个簇中的概率就越大.对调用服务 s 的 9 个用户的 QoS 值进行聚类如图 5 所示.

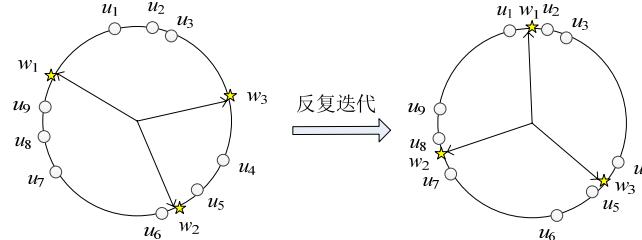


Fig.5 Clustering process of users

图 5 对用户聚类的过程

借鉴文献[14],聚类之前先对用户关系矩阵 M_u 初始化,令所有元素的初始值都为 0;针对调用服务 s 的用户集合 U_s ,使用 SOM 算法进行聚类,初始化神经元权重 w_1, w_2, w_3 ,先计算第 1 个数据(第 1 个用户 u_1 对服务 s 的评分)与 3 个神经元之间的欧式距离,距离最小的神经元 1 获胜,然后根据公式(2)改变获胜神经元 1 的权重 w_1 ;继续计算下一个数据和 3 个神经元的距离,依次类推,每次只有一个神经元获胜并改变对应的权重;直到学习效率小于阈值后,神经元的权重 w_1, w_2, w_3 均趋向于聚类中心,迭代停止.然后根据 SOM 聚类的结果对用户关系矩阵中的元素进行更新,更新规则为:假定用户 i 和用户 j 在服务 s 中被聚类在一个簇中,那么 $u_{ij}=u_{ij}+1$,同时, $u_{ji}=u_{ji}+1$;否则不变.

2.2 Top- k 选择机制

本文提出一种新的 Top- k 选择机制.根据聚类策略,如果两个用户被聚类到同一簇中的次数越多,说明这两个用户对同一个服务的评价越相同或相似,他们在调用同一服务时,彼此之间的服务评价更具有参考性.在聚类时,用 u_{ij} 记录用户 u_i 和用户 u_j 被聚类到同一个簇中的次数,得到用户关系矩阵 M_u ,后对每一行的元素进行从大到小排序,选择前 k 个用户作为目标用户的相似用户,即用户 u_i 的相似用户集为 $f(u_i)=\{a|u_{ia}\geq u_{ik}, u_{ia}>0, a\in U, u_{ik}\in M_u\}$,这样可以减少恶意评价用户的评价对预测结果的影响.以图 2 中调用过服务 s_1 的用户为例,用户 u_1, u_2, u_5 和 u_7 调用过服务 s_1 并给与的评分是 4.2, 4.5, 4.4 和 1.1, 从评分可以推断, 用户 u_7 很可能是一个恶意评价的用户.在聚类时, 用户 u_7 不会与用户 u_1, u_2 和 u_5 聚类到同一个簇中.这样,在相似用户选择时可以排除恶意评价用户,降低其对预测精度的影响.

同样地,对服务进行聚类时,如果两个服务被聚类到同一个簇中的次数越多,说明这两个服务之间的关联度越大,彼此之间的用户评价更具有参考性.因此在聚类结束后,对矩阵 M_s 中的每一行元素值进行从大到小排序,选取前 k 个服务作为目标服务的相似服务,即得到服务 s_i 的相似服务集为 $f(s_i)=\{b|s_{ib}\geq s_{ik}, s_{ib}>0, b\in S, s_{ik}\in M_s\}$.

如图 1 中的例子,现在有一个 9×10 的用户-服务矩阵,包含 9 个用户调用 10 个服务的 QoS 值,其中所有的用户并没调用过所有的服务,根据 SOM 神经网络算法,分别对每一个服务的 QoS 值进行聚类,用 C 矩阵记录不同用户被聚类到同一个簇中的次数,得到更新后的矩阵如下:

$$C = \begin{bmatrix} 0 & 1 & 0 & 1 & 3 & 2 & 0 & 1 & 0 \\ 1 & 0 & 3 & 0 & 1 & 1 & 2 & 0 & 0 \\ 0 & 3 & 0 & 1 & 0 & 2 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 & 0 & 0 & 3 & 1 & 2 \\ 3 & 1 & 0 & 0 & 0 & 1 & 1 & 3 & 0 \\ 2 & 1 & 2 & 0 & 1 & 0 & 1 & 0 & 1 \\ 0 & 2 & 0 & 3 & 1 & 1 & 0 & 2 & 1 \\ 1 & 0 & 1 & 1 & 3 & 0 & 2 & 0 & 3 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 3 & 0 \end{bmatrix}.$$

对每一行的次数从大到小排序后,设置 Top- k 为 2,则得到目标用户的相似用户集,如 u_1 的相似用户集 $f(u_1)=\{u_5, u_6\}$, u_2 的相似用户集 $f(u_2)=\{u_3, u_7\}$, u_3 的相似用户集 $f(u_3)=\{u_2, u_6\}$.

2.3 缺失的QoS值预测

为减少恶意评价用户对预测结果的影响,本文的服务质量预测方法 SOMQP 只考虑相似用户集里的用户.基于相似用户去预测矩阵中缺失值 $R_{u,i}(u)$ 的公式如下:

$$R_{u,i}(u) = \frac{\sum_{t=1}^k (r_{a(t)} \times u_{a(t)})}{N_u} \quad (3)$$

其中, $a(t)$ 是用户 u 的相似用户集里的用户, $r_{a(t)}$ 表示相似用户 $a(t)$ 的 QoS 值, $u_{a(t)}$ 表示用户 u 与相似用户 $a(t)$ 被聚类到同一个簇中的次数, N_u 表示用户 u 与所有相似用户被聚类到同一个簇中的次数总和.

同样地,基于相似服务的预测缺失值 $R_{u,i}(i)$ 的公式如下:

$$R_{u,i}(i) = \frac{\sum_{t=1}^k (r_{b(t)} \times u_{b(t)})}{N_s} \quad (4)$$

其中, $b(t)$ 是服务 i 的相似服务集里的服务, $r_{b(t)}$ 表示相似服务 $b(t)$ 的 QoS 值, $u_{b(t)}$ 表示服务 i 与相似服务 $b(t)$ 被聚类到同一个簇中的次数, N_s 表示服务 i 与所有相似服务被聚类到同一个簇中的次数总和.

为了充分考虑相似用户和相似服务的信息,本文结合公式(3)和公式(4),提出一种混合的预测方法 SOMQP,如下:

$$R_{u,i} = \lambda \times R_{u,i}(u) + (1-\lambda) \times R_{u,i}(i) \quad (5)$$

其中,参数 λ 表示预测值依赖相似用户和相似服务的比例.当 $\lambda=1$ 时,仅使用基于用户的方法进行预测;当 $\lambda=0$ 时,仅使用基于服务的方法进行预测;如果用户 u 没有调用过任何服务,而服务 i 也没有被任何用户调用过,则使用所有服务 QoS 值的平均值进行预测.

3 实验结果与分析

本文在真实的数据集上做了大量实验来比较所提出的方法与目前经典的相关方法的预测精度,同时研究不同的参数对预测精度的影响.本部分实验环境是 IntelliJ IDEA Community Edition 14.1.4,jdk 1.7,scala-sdk 2.10.4,编程语言 scala,实验机器配置为 16G 内存,core i7-4970 3.6GHZ 处理器,ubuntu 14.04 LTS 系统.

3.1 实验数据

在实验中,为评价本文提出的 SOMQP 的服务质量预测方法的有效性,我们使用 WS-Dream 数据集^[26],这个数据集中两个矩阵分别包含 339 用户调用 5 825 个服务产生的 1 974 675 个 Web 服务的响应时间(response time,简称 RT)和吞吐量(throughput,简称 TP)的真实记录值,其中,83.7% 的响应时间值在 [0,1] 之间.真实世界中,大部分用户都只调用过少数的服务,所以产生的用户-服务矩阵是一个稀疏矩阵,为此,我们随机移出一部分数据作为训练集,剩余的作为测试集.在 WS-Dream 数据集中,训练集的比例为 0.05,0.1,0.15,0.2,0.25.

3.2 评价指标

为评价服务质量预测的有效性,本文在数据集上划分多个训练集进行实验;同时,也在不同相似用户数和相似服务数的基础上进行验证.本文选择两个度量预测 QoS 值质量的指标是绝对平均误差(MAE)和均方根误差(RMSE),分别定义如下:

$$MAE = \frac{\sum_{u,s} |R(u,s) - P(u,s)|}{N} \quad (6)$$

$$RMSE = \sqrt{\frac{\sum_{u,s} (R(u,s) - P(u,s))^2}{N}} \quad (7)$$

其中, $R(u,s)$ 表示用户 u 调用服务 s 得到的实际 QoS 值, $P(u,s)$ 表示预测的值, N 表示预测值的数量.MAE 是通过比较用户调用服务的真实 QoS 值和预测值之间差异值来计算的,它的值越小,表示预测精度越高.

3.3 实验结果与分析

为评价所提出的 SOMQP 方法的预测精度,选择以下经典方法在 MAE 和 RMSE 两个指标上进行对比实验.

- 1) UPCC(基于用户的协同过滤方法):该方法基于相似用户的历史 QoS 值去预测缺失值.
- 2) IPCC(基于项目的协同过滤方法):该方法基于相似服务的历史 QoS 值去预测缺失值.
- 3) UIPCC(混合的协同过滤方法):该方法是分别给与 UPCC 和 IPCC 一个权重,用综合的方法去预测缺失的值.
- 4) KUPCC:借鉴文献[14],用 K -means 方法对用户进行聚类,得到用户关系矩阵并寻找相似用户,然后基于相似用户对缺失 QoS 值进行预测.
- 5) KIPCC:用 K -means 方法对服务进行聚类,得到服务关系矩阵并寻找相似服务,然后基于相似服务对缺失 QoS 值进行预测.
- 6) KUIPCC:基于 KUPCC 和 KIPCC 混合策略对缺失 QoS 值进行预测.
- 7) TOSEM:该方法基于改进的 PCC 来计算用户或服务之间的相似度,进而用综合方法去预测缺失值^[26].
- 8) SUPCC:用 SOM 神经网络算法对用户进行聚类寻找相似用户,基于相似用户对缺失 QoS 值进行预测.
- 9) SIPCC:用 SOM 神经网络算法对服务进行聚类寻找相似服务,基于相似服务对缺失 QoS 值进行预测.

实验中,在 WS-Dream 数据集上设置矩阵密度从 0.05~0.25,以 0.05 的间隔逐渐增加,Top- k 相似用户和相似

服务中, $k=2$,在公式(5)中的 $\lambda=0.4$,分别求得这几种方法在响应时间和吞吐量上的 MAE 和 RMSE,实验结果比较见表 1 和表 2.

Table 1 Comparison between SOMQP and other methods on RT

表 1 SOMQP 与其他方法在 RT 上的比较

方法	MAE/矩阵密度					RMSE/矩阵密度					
	0.05	0.1	0.15	0.2	0.25	平均	0.05	0.1	0.15	0.2	0.25
UPCC	0.637	0.531	0.496	0.472	0.451	0.517	1.513	1.372	1.343	1.295	1.272
IPCC	0.869	0.854	0.832	0.815	0.786	0.831	1.682	1.668	1.642	1.583	1.512
UIPCC	0.663	0.595	0.541	0.496	0.465	0.552	1.459	1.415	1.377	1.356	1.328
KUPCC	0.538	0.466	0.435	0.415	0.403	0.451	1.579	1.446	1.405	1.358	1.342
KIPCC	0.405	0.379	0.351	0.343	0.336	0.363	1.363	1.276	1.272	1.249	1.241
KUIPCC	0.418	0.393	0.365	0.353	0.345	0.375	1.297	1.221	1.210	1.174	1.168
TOSEM	0.652	0.525	0.481	0.454	0.435	0.509	1.447	1.302	1.258	1.211	1.196
SUPCC	0.491	0.436	0.411	0.392	0.381	0.422	1.520	1.415	1.374	1.327	1.314
SIPCC	0.406	0.371	0.362	0.352	0.346	0.367	1.370	1.285	1.286	1.259	1.254
SOMQP	0.399	0.362	0.358	0.342	0.335	0.359	1.306	1.227	1.209	1.196	1.192

Table 2 Comparison between SOMQP and other methods on TP

表 2 SOMQP 与其他方法在 TP 上的比较

方法	MAE/矩阵密度					RMSE/矩阵密度					
	0.05	0.1	0.15	0.2	0.25	平均	0.05	0.1	0.15	0.2	0.25
UPCC	26.858	21.688	18.865	17.923	16.698	20.406	65.225	57.476	53.148	51.007	49.019
IPCC	37.341	36.862	35.013	33.695	30.218	34.625	74.322	71.061	68.430	63.697	59.077
UIPCC	27.642	25.425	24.768	23.242	21.571	24.529	62.869	58.116	56.348	54.189	53.662
KUPCC	17.211	15.287	14.239	13.777	13.254	14.754	55.502	50.816	48.399	47.159	45.759
KIPCC	15.837	14.285	13.199	12.734	12.247	13.660	55.208	51.401	48.727	47.315	45.749
KUIPCC	14.847	13.373	12.162	11.719	11.285	12.677	50.337	46.572	41.618	40.351	39.141
TOSEM	26.827	22.648	20.702	19.675	17.954	21.561	62.116	55.222	51.218	50.713	50.055
SUPCC	17.128	15.246	14.093	13.706	12.208	14.476	54.499	50.789	48.116	46.877	45.521
SIPCC	15.775	14.191	13.055	12.635	12.110	13.553	54.029	49.853	46.977	45.773	43.888
SOMQP	14.420	13.044	11.980	11.618	11.154	12.443	46.869	43.328	41.108	39.943	38.514

从实验结果可知:在矩阵密度相同的情况下,本文方法的 QoS 预测精度最好;同时,随着矩阵密度的增大,本文方法的预测精度一直优于其他方法,而且稀疏度越大时,本文方法与其他方法的预测精度的差距越大.表 1 中展示的是本文提出的 SOMQP 和其他经典算法在响应时间上的比较,从实验结果可以得出,SOMQP 方法在 MAE 上比 UIPCC,KUIPCC,TOSEM 这 3 种经典方法分别提高 34.9%,4.3%,29.5%.同样地,表 2 中是在吞吐量数据集上的比较,本文的算法比上述 3 个算法在 MAE 上平均值分别提高 49.5%,1.8% 和 42.3%.综上可以看出,在不同的数据集上,本文提出的 SOMQP 算法的预测精度比这几种经典算法都有一定的提高.该实验结果表明,本文方法可以更好地选取目标用户的相似用户来进行缺失值预测,同时降低那些恶意评价用户对预测精度的影响.

(1) λ 对预测精度的影响

在本文的方法中,参数 λ 是决定 SOMQP 方法依靠相似用户和相似服务的权重,若 $\lambda=1$ 时,仅使用基于用户的方法进行预测;若 $\lambda=0$ 时,仅使用基于服务的方法进行预测.为研究 λ 对预测结果的影响,本文在 WS-Dream 数据集上,设置矩阵密度为 0.05,相似用户数和相似服务数为 2 的情况下, λ 的值从 0.1 到 0.9 并以 0.1 的间隔逐渐增加对 MAE 和 RMSE 的影响,实验结果如图 6 所示.

其中,图 6(a)、图 6(b)是在响应时间的实验结果,图 6(c)、图 6(d)是在吞吐量上的实验结果.图 6 的实验结果表明,参数 λ 的值对 SOMQP 方法的预测精度有很重要的影响.从图 6(a)、图 6(c)中看出,一开始,随着 λ 值的增大,预测精度一直在提高,当预测精度达到最大值之后,随着 λ 值的增大,预测精度开始降低;图 6(a)中,在 $\lambda=0.2$ 时,预测精度达到最优值;图 6(c)中,在 $\lambda=0.4$ 时,预测精度达到最优值.这表明,一个合适的 λ 值可以达到更好的预测精度.同时,图 6(a)、图 6(c)的结果表明,在不同的数据集上,达到最优预测精度时的 λ 值不一样的.

(2) Top- k 对预测的影响

本文方法中参数 Top- k 决定了选取目标用户的相似用户数或目标服务的相似服务数.为研究 Top- k 值对预

测精度的影响,实验用 WS-Dream 数据集分别在响应时间和吞吐量两个属性上,在矩阵密度为 0.05, $\lambda=0.4$,设置 Top- k 值为从 1~6 并以 1 的间隔逐渐增加对 MAE 和 RMSE 的影响,结果如图 7 所示.

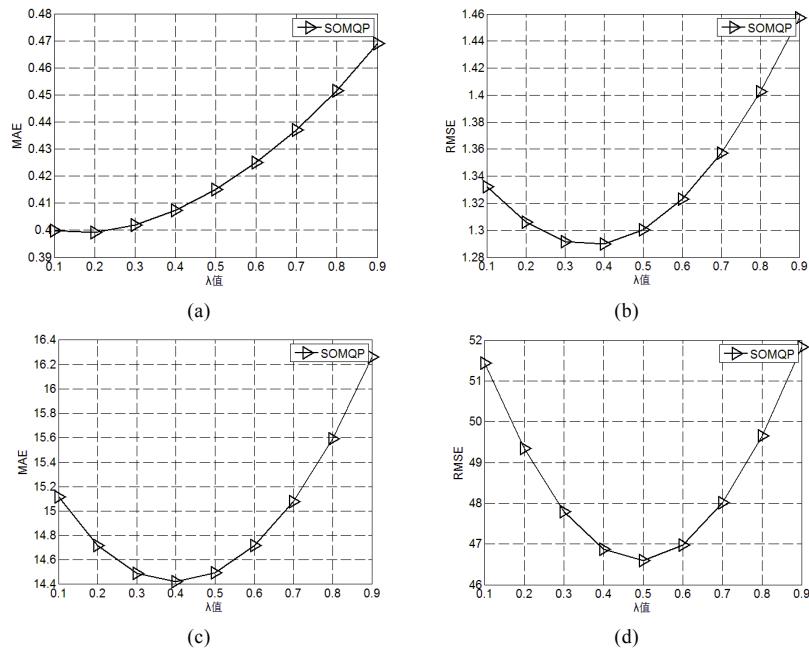


Fig.6 Impact of λ on prediction accuracy

图 6 λ 对预测精度的影响

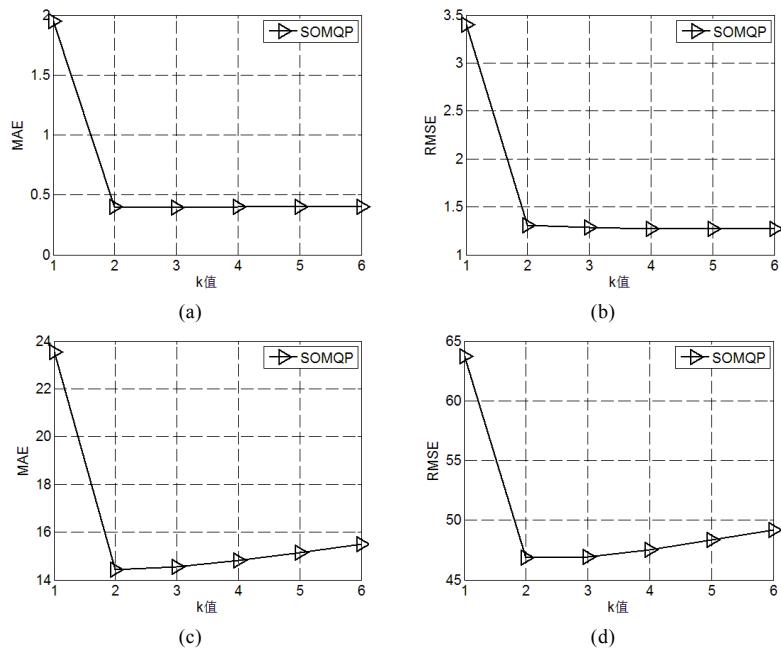


Fig.7 Impact of Top- k on prediction accuracy

图 7 Top- k 对预测精度的影响

其中,图 7(a)、图 7(b)是在响应时间的实验结果,图 7(c)、图 7(d)是在吞吐量上的实验结果.从图 7(a)、图 7(c)可以看出,随着 k 值的增加,预测精度先变大然后变小,并在 k 为 2 时达到最大.这说明相似用户或相似服务数越多,并不一定有利于提高预测精度.相似用户数和相似服务数过少或过多,都会降低预测精度:如果相似用户数太少,不能全面考虑用户之间的关系;如果相似用户数太多,则不能排除那些对服务进行恶意评价的用户,这些恶意评价的用户会对预测精度有很大的影响.同样地,相似服务数越多,那些被用户恶意评价的服务信息会大大降低预测精度.

(3) 矩阵密度的影响

矩阵密度表示从用户-服务矩阵中移出作为训练集的数据比例.图 8 是在 WS-Dream 数据集上,分别对响应时间和吞吐量两个 QoS 属性研究矩阵密度的影响.设置矩阵密度从 0.05 到 0.25,以 0.05 的间隔增加, $\lambda=0.4$,相似用户数和相似服务数为 2.

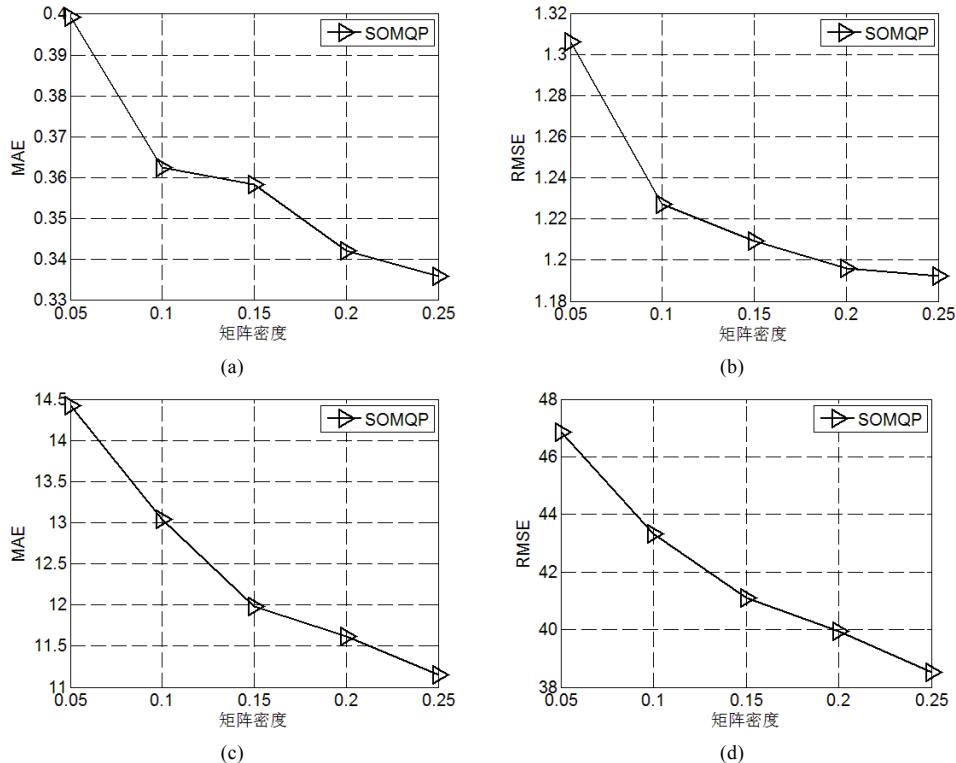


Fig.8 Impact of matrix density on prediction accuracy

图 8 矩阵密度对预测精度的影响

从图 8 可以看出,随着矩阵密度的增加,SOMQP 方法的服务质量预测精度也逐步提高.这是因为矩阵密度越大,说明更多的用户调用过更多的服务,所产生的数据集中包含更多的用户信息和服务信息,可以从这些信息中挖掘更多有用信息来提高预测精度.

4 结束语

本文提出一种基于 SOM 神经网络的服务质量预测方法 SOMQP.首先根据历史 QoS 数据,用 SOM 分别对用户和服务进行聚类,得到用户关系矩阵和服务关系矩阵;然后,基于一种新的 Top- k 选择机制,获得目标用户和目标服务的相似用户集和相似服务集;最后,结合基于相似用户的和基于相似服务的方法,提出一个混合策略对

缺失 QoS 值进行预测。在真实数据集上的实验结果表明,与经典的 CF 算法、基于改进的 PCC 预测算法和 K-means 聚类算法相比,我们方法的质量预测精度分别提高了 34.9%、29.5% 和 4.3%。随着服务规模的增大,用户-服务信息矩阵也变得越来越大,在接下来的研究中,将在 Spark 平台使用并行聚类技术来验证本文算法的有效性和稳定性。

References:

- [1] Yin J, Tang Y, Lo W, Wu Z. From big data to great services. In: Proc. of the 2016 IEEE Int'l Congress on Big Data (BigData Congress). IEEE, 2016. 165–172.
- [2] Yu Y, Chen J, Lin S, Wang Y. A dynamic QoS-aware logistics service composition algorithm based on social network. IEEE Trans. on Emerging Topics in Computing, 2014,2(4):399–410.
- [3] Chattopadhyay S, Banerjee A. QSCAS: QoS aware Web service composition algorithms with stochastic parameters. In: Proc. of the 2016 IEEE Int'l Conf. on Web Services (ICWS). IEEE, 2016. 388–395.
- [4] He Q, Han J, Chen F, Wang Y, Vasa R, Yang Y, Jin H. QoS-Aware service selection for customisable multi-tenant service-based systems: Maturity and approaches. In: Proc. of the 2015 IEEE 8th Int'l Conf. on Cloud Computing. IEEE, 2015. 237–244.
- [5] Dahan F, El Hindi K, Ghoneim A. Enhanced artificial bee colony algorithm for QoS-aware Web service selection problem. Computing, 2017,99(5):507–517.
- [6] Liu SD, Meng XB. Approach to network services recommendation based on mobile users' location. Ruan Jian Xue Bao/Journal of Software, 2014,25(11):2556–2574 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/4561.htm> [doi: 10.13328/j.cnki.jos.004561]
- [7] Xu Y, Yin J, Deng S, Xiong N, Huang J. Context-Aware QoS prediction for Web service recommendation and selection. Expert Systems with Applications, 2016,53:75–86.
- [8] Su K, Xiao B, Liu B, Zhang H, Zhang Z. TAP: A personalized trust-aware QoS prediction approach for Web service recommendation. Knowledge-Based Systems, 2017,115:55–65.
- [9] Shao LS, Zhou L, Zhao JF, Xie B, Mei H. Web service QoS prediction approach. Ruan Jian Xue Bao/Journal of Software, 2009, 20(8):2062–2073 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/3375.htm> [doi: 10.3724/SP.J.1001.2009.03375]
- [10] Wang Y, He Q, Yang Y. QoS-Aware service recommendation for multi-tenant SaaS on the cloud. In: Proc. of the 2015 IEEE Int'l Conf. on Services Computing (SCC). IEEE, 2015. 178–185.
- [11] Hu Y, Peng Q, Hu X, Yang R. Time aware and data sparsity tolerant Web service recommendation based on improved collaborative filtering. IEEE Trans. on Services Computing, 2015,8(5):782–794.
- [12] Wang X, Zhu J, Zheng Z, Song W, Shen Y, Lyu MR. A spatial-temporal QoS prediction approach for time-aware Web service recommendation. ACM Trans. on the Web, 2016,10(1):No.7.
- [13] Zhang X, Wang Z, Lv X, Qi R. A clustering-based QoS prediction approach for Web service selection. In: Proc. of the 2013 Int'l Conf. on Information Science and Cloud Computing Companion (ISCC-C). IEEE, 2013. 201–206.
- [14] Wu C, Qiu W, Zheng Z, Wang X, Yang X. QoS prediction of Web services based on two-phase K-means clustering. In: Proc. of the 2015 IEEE Int'l Conf. on Web Services (ICWS). IEEE, 2015. 161–168.
- [15] Yu C, Huang L. CluCF: A clustering CF algorithm to address data sparsity problem. In: Proc. of the Service Oriented Computing and Applications. 2016. 1–13.
- [16] Sarwar B, Karypis G, Konstan J, Riedl J. Item-Based collaborative filtering recommendation algorithms. In: Proc. of the 10th Int'l Conf. on World Wide Web. ACM Press, 2001. 285–295.
- [17] Zheng Z, Ma H, Lyu M R, King I. Wsrec: A collaborative filtering based Web service recommender system. In: Proc. of the 2009 IEEE Int'l Conf. on Web Services (ICWS 2009). IEEE, 2009. 437–444.
- [18] Zhao Y, Pi Q, Luo C, Yan D. CAPred: A prediction model for timely QoS. In: Proc. of the 2015 IEEE Int'l Conf. on Web Services (ICWS). IEEE, 2015. 599–606.
- [19] Chen L, Yang J, Zhang L. Time based QoS modeling and prediction for Web services. In: Proc. of the Int'l Conf. on Service-Oriented Computing. Berlin, Heidelberg: Springer-Verlag, 2011. 532–540.

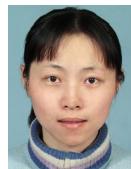
- [20] Lo W, Yin J, Li Y, Wu Z. Efficient Web service QoS prediction using local neighborhood matrix factorization. *Engineering Applications of Artificial Intelligence*, 2015, 38: 14–23.
- [21] Zhu J, Kang Y, Zheng Z, Lyu MR. A clustering-based QoS prediction approach for Web service recommendation. In: Proc. of the 2012 15th IEEE Int'l Symp. on Object/Component/Service-Oriented Real-Time Distributed Computing Workshops. IEEE, 2012. 93–98.
- [22] Chen F, Yuan S, Mu B. User-QoS-Based Web service clustering for QoS prediction. In: Proc. of the 2015 IEEE Int'l Conf. on Web Services (ICWS). IEEE, 2015. 583–590.
- [23] Zhang M, Liu X, Zhang R, Sun H. A Web service recommendation approach based on QoS prediction using fuzzy clustering. In: Proc. of the 2012 IEEE Ninth Int'l Conf. on Services Computing (SCC). IEEE, 2012. 138–145.
- [24] Kohonen T. The self-organizing map. *Proc. of the IEEE*, 1990, 78(9): 1464–1480.
- [25] Cottrell M, Olteanu M, Rossi F, Villa-Vialaneix N. Theoretical and applied aspects of the self-organizing maps. In: Proc. of the Advances in Self-Organizing Maps and Learning Vector Quantization. Springer Int'l Publishing, 2016. 3–26.
- [26] Zhang Y, Zheng Z, Lyu MR. WSPred: A time-aware personalized QoS prediction framework for Web services. In: Proc. of the 2011 IEEE 22nd Int'l Symp. on Software Reliability Engineering (ISSRE). IEEE, 2011. 210–219.

附中文参考文献:

- [6] 刘树栋,孟祥武.一种基于移动用户位置的网络服务推荐方法.软件学报,2014(11):2556–2574. <http://www.jos.org.cn/1000-9825/4561.htm> [doi: 10.13328/j.cnki.jos.004561]
- [9] 邵凌霜,周立,赵俊峰,谢冰,梅宏.一种 Web Service 的服务质量预测方法.软件学报,2009,20(8):2062–2073. <http://www.jos.org.cn/1000-9825/3375.htm> [doi: 10.3724/SP.J.1001.2009.03375]



张以文(1976—),男,安徽马鞍山人,博士,副教授,CCF 专业会员,主要研究领域为服务计算,云计算,大数据.



贾兆红(1976—),女,博士,副教授,CCF 专业会员,主要研究领域为多目标优化算法,组合优化.



项涛(1989—),男,硕士,主要研究领域为服务推荐.



何强(1982—),男,博士,高级讲师,博士生导师,主要研究领域为面向服务的软件工程,大数据.



郭星(1983—),男,博士,讲师,CCF 专业会员,主要研究领域为服务计算,智能算法.