

文章编号: 2096-1618(2021)01-0051-11

一种基于用户在线行为分析的 Web 服务动态 QoS 评估方法

王瑞祥, 魏乐, 常钰, 段燕飞
(成都信息工程大学软件工程学院, 四川 成都 610225)

摘要:随着以计算机为中心的 Web 服务提供方式向以用户需求为中心的方式转变, 针对以往动态 QoS 模型未能充分考虑用户在线行为等因素, 导致服务质量的评估缺乏实时准确性, 文中通过考虑用户在线行为所造成的 Web 服务流行度失衡及流行热度的区域性变化等因素, 对服务流行性的评估建立算法模型, 采用 Logistic 增长曲线和种群增长速率曲线的思想描述用户在线行为变化, 并基于遗忘算法提出了服务流行热度值评估算法, 能够根据单位时间内服务请求数量增长率的变化趋势, 来自适应调整流行性的数值, 又通过聚类算法对服务请求的热点位置密度进行划分, 解决了流行热度的区域性变化问题。而后将流行性作为动态 QoS 模型的一项重要指标, 并对模型进行重构与调整, 通过建立数据误差评估、归一化和动态加权的方案实现了 QoS 属性的动态合成, 最后通过实验验证了该模型可行有效。

关键词: Web 服务; 服务质量; 流行热度; 在线行为; QoS 建模

中图分类号: TP311

文献标志码: A

doi: 10.16836/j.cnki.jcuit.2021.01.009

0 引言

近年来伴随信息技术的飞速发展和云端服务的日渐增多, 人们从 Web 应用服务数据匮乏的时代跨进了“信息过载”的时代, 推荐技术为处理互联网上的海量数据提供了便捷的途径^[1]。在当今大数据的时代背景和服务计算智能化的整体框架下, 用户在线行为成为了智能化服务计算研究中不可忽视的因素, 服务计算从“服务发展改变用户需求”向“用户需求引导服务发展”的方向不断迈进。用户在线行为在 Web 服务计算中主要体现于在线搜索行为、网上购物行为、浏览行为、标注行为、评论行为以及社交行为等, 对于这方面的数据分析技术和方法主要涉及搜索意图的分析、购物模式的发现、周期行为的挖掘、标签的有效聚类、评论意见的挖掘、用户偏好的发现、个性化推荐方法等。随着 2019 年国际推荐系统大会 (RecSys2019) 演讲者 Eszter Hargittai 所提出的“人们的在线行为”等因素, 不同服务之间人们在线行为的差异以及人们的在线行为是如何导致推荐系统出现偏差的等研究热点^[2], 引导越来越多的研究学者考虑用户在线行为所带来的影响。例如利用用户在线行为数据解决推荐过程中数据稀疏性问题, 文献[3]根据用户的在线行为逻辑, 构造了一个基于循环神经网络的用户行为仿真

器, 向强化学习提供模拟的用户反馈, 解决推荐过程中用户-服务矩阵数据稀疏的问题; 文献^[4-5]提出了一种基于用户行为的聚类算法, 通过考虑用户在线行为信息, 对不同的用户行为赋予不同的线性权重, 将用户行为转换成对项目的评分用以填充稀疏的用户-项目评分矩阵, 但不管是仿真模拟反馈的数据还是聚类相似行为的用户, 其目的都是为了填充稀疏矩阵, 却忽略了在线行为数据真实反映广大用户需求的优势, 从而使得数据缺乏真实性和实时性, 不足以体现其影响力。文献[6]通过挖掘用户的在线行为发生机制, 让人们更深刻地认识自身与发现人类的行为特征, 帮助人们更高效且更精确地找到想要的信息, 但只体现了个体行为数据对自身特征的发现, 却忽略了总体行为数据对个体需求的影响, 使推荐具有片面性。文献[7]通过对用户与服务之间的位置信息挖掘, 从而找到最近相似邻居集合; 文献[8]利用位置信息, 建立位置消费图, 计算位置远近对目标用户的影响, 从而找到最近邻居集, 对于基于在线行为进行空间位置分析, 大多只考虑了实际物理距离, 而未曾发掘 Web 服务是部署在互联网上, 利用实际空间位置远近进行推荐预测并不合理有效, 应该利用空间聚类发现其潜在的影响力, 分析在线行为所描绘的虚拟空间位置更具有合理性。通过对以上文献中所描绘的思想以及体现的问题进行分析, 从而为动态服务质量模型的研究开辟了新的思路。

收稿日期: 2020-08-27

基金项目: 四川省应用基础研究资助项目 (2018JY0506); 四川省教育厅青年基金重点资助项目 (16ZA0208)

Web 服务作为一种无形的产品,更关心的是服务质量(quality of services, QoS)的优劣^[9],针对 Web 服务的非功能性属性和用户需求进行动态 QoS 建模的研究也颇多^[10]。在众多推荐算法中,基于服务质量 QoS 评估值进行推荐仍然是最具准确性的一种方式,而用户在线行为最能体现某项 Web 服务在不同时空段内的质量与优劣。Deepanshu Bharadwaj 曾提到:人们通常会受到大多数人的影响而做出行为选择,广大用户对于不同厂商但具有相同功能的 Web 服务的在线选择行为,直接划分了互联网上 Web 服务的优劣与等级,间接引导了用户选择与需求的方向^[11],所以理应在个性化推荐技术中,评估 Web 服务在近段时间内的用户在线行为所造成的服务质量的波动和影响,并把用户在线行为的评估算法植入 QoS 评估模型中。如今在互联网生态系统中,新闻资讯、音视频服务、微博服务中都或多或少存在热度榜单,热度榜单最为直接地体现了人们在线行为的分布与选择。对于 Web 应用服务来说,具有相似功能的不同服务的流行热度的改变,就能够准确地描述用户在线行为的变化,以 Web 服务流行热度值作为 QoS 评估的一项重要因素,来描述用户在线行为在不同时刻的动态变化对服务质量的动态调控。

文中首先阐述什么是用户在线行为,用户在线行为如何对当今 Web 服务带来流行度失衡及流行热度的区域性变化的较大影响,然后对传统 QoS 指标的动态性进行改进和分析,通过充分考虑时间变化对各属性值的影响程度,对整个 QoS 评估模型的各个属性进行完整的定义和描述,并把服务流行热度作为 QoS 评估的重要指标,研究如何构建合适的算法及函数来描述用户在线行为导致服务流行热度的不断变化,从而来调控 QoS 综合评估值的动态变化,提出了服务流行热度值评估算法模型以及服务请求热点位置密度划分算法,最终对多数据源和多属性集成的动态 QoS 综合评估模型^[12]进行重构、改进与调整,并实验验证其可行性,为服务推荐更加智能化提供了前提。

1 QoS 模型描述及相关定义

1.1 模型基本描述

QoS 是对服务或者产品完成用户需求目标能力的描述,Web 应用服务的 QoS 通常是非功能性需求的描述,具体包括哪些指标目前尚未拥有明确的官方定义,常用的非功能性指标主要包括服务代价、请求响应时间、服务状态、可靠性、安全性等。随着用户在线行为

对服务发展的影响日益增大,常用的属性指标已经无法准确衡量服务质量的优劣,QoS 指标的确立迫切需要依据场景制定,不可避免地会涉及更多评价指标属性等。

如今国内外对于服务 QoS 评估建模有较多考虑时空数据的动态变化,例如运用离散随机变量或连续概率分布等概率分布模型描述 QoS 属性,较大程度体现了 QoS 属性的动态性^[13],以及精确描述时间变化影响进行 QoS 建模^[14],但基于用户在线行为分析对 QoS 建模相对较少,用户在线行为变化也体现在时空数据的变化中。基于文献[12]所描述的 QoS 模型,针对用户在线行为因素,对其进行改进重点考虑 2 点:随时间推移对流行性评估的影响;随空间变化对流行性评估的影响。用户在线行为更多体现在其所处的空间随时间变化而不断变化,如何描述用户在线数据时空变化的规律是体现用户在线行为对 Web 服务流行热度值影响的关键。综上所述,对传统建模进行适当改进与重构,使 QoS 评估结果更为准确地贴合用户需求,模型描述如图 1 所示。

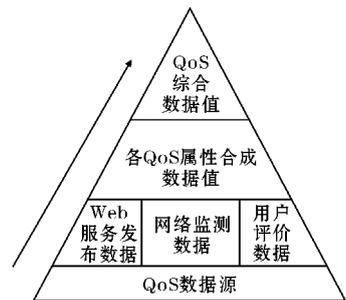


图1 QoS 动态评估模型

定义1 服务,指为社会及用户提供生活便利,依托 Internet 的海量数据信息、计算资源及应用资源并以 Web 的形式提供业务的应用程序。定义服务 Service 用 S 表示; $S=(ID, QoS)$,其中: ID 为服务 S 的标识符。 QoS 表示为服务质量,具体表示为 $QoS=(Reliability, Timeliness, Cost, Security, Adaptive, Popularity)$,各元素分别代表可靠性、时效性、服务价格、安全性、适应性及流行性,把流行性作为 QoS 评估的重要指标,是依据用户在线行为数据对 QoS 评估进行动态调控的基础。

定义2 QoS 综合评估(QoS comprehensive evaluation),通过对 QoS 各属性指标按一定的规范化算法和评价标准计算出的综合评价价值。如图 1 动态评估模型所示,QoS 综合评估分别由 Web 服务发布数据、网络监测数据及用户评价数据 3 个数据源为基础,经过两级数据合成。其中,QoS 合成数据由 3 个数据源所提供的 QoS 数据经自适应处理后动态合成,QoS 综合数据由 QoS 合成数据经过集成计算得出。

1.2 模型计算

QoS 评估模型的核心是如何定义属性以及提供属性数据的来源,而对于各指标属性如何进行计算和描述目前尚没有统一的定论,诸如可靠性、时效性、适应性等大多都从服务使用的角度量化其属性值。需在多数据源^[12]的基础上,结合用户在线行为数据,针对属性指标值随时空因素动态变化的影响,重新量化各属性值的表示与计算,使 QoS 各属性的评估更好地描述用户在线行为的变化,其相关定义如下。

定义 3 QoS 数据源,指需要接受评估的 QoS 属性指标数据信息的来源,共设置 3 个数据源^[12],其分别为服务商 (Service Provider) 公布的数据,网络检测 (Monitor) 的数据以及用户评价行为 (User) 数据,为计算方便可简化表示,服务商为 P 、网络检测为 M 、用户评价为 U ,服务 S_i 中的 QoS 数据都是由这 3 个数据源所提供,则为服务 S_i 所提供数据的 3 个数据源可表示为 P_i, M_i, U_i 。

定义 4 QoS,由定义 1 可知,QoS 是服务 S_i 中的一个元素,定义为服务质量,是多数据源及多指标集成的动态评估 QoS 综合数据值,对于特指单个服务 S_i 中的 QoS 而言,为便于计算,可定义为一个行向量:

$$q_i = (r_i, t_i, c_i, s_i, ad_i, p_i) \quad (1)$$

其中: $i \in (1, 2, \dots, n)$, r_i 为服务 S_i 的可靠性, t_i 为时效性, c_i 为服务价格, s_i 为安全性, ad_i 为适应性, p_i 为服务 S_i 的流行性,每项 Web 服务中各 QoS 均以竖向量 q_i 表示。 q_i 中的各个属性值由 3 个数据源所提供,为利于计算,结合文献^[12]的表示方法,各属性分别表示如下:

$$\begin{cases} r_i = (p_{r,i}, m_{r,i}, u_{r,i})^T \\ t_i = (p_{t,i}, m_{t,i}, u_{t,i})^T \\ c_i = (p_{c,i}, m_{c,i}, u_{c,i})^T \\ s_i = (p_{s,i}, m_{s,i}, u_{s,i})^T \\ ad_i = (p_{ad,i}, m_{ad,i}, u_{ad,i})^T \\ p_i = (p_{p,i}, m_{p,i}, u_{p,i})^T \end{cases} \quad (2)$$

各 QoS 属性的形式化定义均由 3 个数据源构成的行向量的转置表示,由上述公式可知 QoS 各指标与数据源形成了一个矩阵,可以清楚地表示属性与数据源之间的密切关系,6 个属性为行坐标,3 个数据源为纵坐标,矩阵中不同位置对应各自的数据。此外,这 6 项属性分别对应一个数值,仅仅在计算时才将其视作 6 个不同的向量。各 QoS 属性值计算如下定义:

可靠性 r_i 。具体指单位时间下 Web 服务运行中保持正常响应的概率,其数值计算以百分比的形式表

示,计算所得的数据由监测数据 M 所提供,服务商 P 和用户 U 的期望数据由各自直接给出。该属性计算依靠失效率与可靠率的关系^[15],设在某时段 $\Delta t = t_j - t_k$ 内,服务 S_i 在 t_j 时刻累计被用户所调用 a_j 次,共成功完成服务响应次数为 c_j ;在 t_k 时刻累计被用户调用 a_k 次,共成功完成服务响应 c_k 次。在 t_j 时刻的失效服务次数为 $j = a_j - c_j$;在 t_k 时刻失效的服务次数为 $k = a_k - c_k$,服务 S_i 在 Δt 时刻内单位时间的失效率为 $\lambda(S_i) = \frac{j-k}{(a_j-a_k)\Delta t}$,则其可靠性计算表示为

$$r(S_i) = 1 - \lambda(S_i) = 1 - \frac{j-k}{(a_j-a_k)\Delta t} \quad (3)$$

时效性 t_i 。指用户调用服务 S_i 的响应时间及信息更新的时间,其数值以时间单位 ms 表示,由监测数据 M 计算提供,服务商 P 和用户 U 的期望数据由各自直接给出。设 T_s 为服务处理时间, T_d 为用户发送服务调用请求和接受服务响应的消息传输时延,则时效性表示为 $t(S_i) = T_s + T_d$ 。

服务价格 c_i 。由服务商 P 提供数据,只需归一化即可,其数值为实数。

安全性 s_i 。指服务 S_i 对于用户隐私保护的等级,对文献^[16]的隐私扰动算法加以改进使用。其等级由整数所表示,计算所得的数据由监测数据 M 所提供,服务商 P 和用户 U 的期望数据由各自直接给出,则根据服务 S_i 设定和用户需求,对用户提供的信息数据扰动的等级为

$$S_i = \frac{MAXDistuibaanceRange}{1 + e^{-UserExpect}} \quad (4)$$

数值范围 $[0, 5]$,其中 $MAXDistuibaanceRange$ 数值即为服务商 P 所提供的安全性 s_i 数值, $UserExpect$ 由用户 U 对服务 S_i 安全性期望均值。

适应性 ad_i 。表示服务 S_i 应对动态环境的调整策略,具体指服务 S_i 由于用户在线行为所导致的 S_i 热点中心位置 HSC (HotspotCenter) 变化同时,该服务 S_i 流行性 p_i 能否自适应保持稳定的等级,数据以百分比的形式表述,计算所得的数据由监测数据 M 所提供,该属性算法如下:

(i) 若 Δt 时间内,服务 S_i 的 HSC 存在变化, $\Delta t = t_k - t_j$,设在 t_k 时刻,服务 S_i 的流行性为 $p_{i,k}$,在 t_j 时刻服务 S_i 的流行性为 $p_{i,j}$,服务 S_i 的流行性范围记为 $[p_{\min}, p_{\max}]$,服务 S_i 的流行性 p_i 的变化率为

$$r_p = \frac{|p_{i,k} - p_{i,j}|}{p_{\max} - p_{\min}} \quad (5)$$

即服务 S_i 适应性为

$$ad_i = 1 - r_p = 1 - \frac{|p_{i,k} - p_{i,j}|}{p_{\max} - p_{\min}} \quad (6)$$

(ii)若 Δt 时间内,服务 S_i 的HSC没有变化,则命名该情况为无动态环境变化 NCIDE(no change in dynamic environment),适应性数值计算由各服务 ad_i 均值构成:

$$ad_i = NCIDE = \frac{\sum_{i=1}^n ad_i}{n} \quad (7)$$

流行性 p_i 。该属性是文中所述评估模型的核心,随着用户的在线搜索、浏览、标注、评论行为以及社交等情景因素构成的用户在线行为,造成服务 S_i 的点击率或使用率的动态变化,由流行热度 p_i 体现,用等级描述, $p_i = n, n \in [0, 10], p_i$ 的等级 n 具体由服务流行热度值评估算法模型(service popularity evaluation algorithm model, SPEAM)得出。

2 服务流行热度值评估算法模型

2.1 基本假设与描述

用户在线行为对服务的QoS影响具体体现在服务流行性指标 p_i 的动态变化,广大用户群体对不同Web服务的浏览及使用直接决定了Web服务在不同时段的流行热度值,流行性的评估完全依赖于用户的行为数据,通过用户行为数据感知不同Web服务的活跃程度,数据流量越活跃的服务则其流行热度值越高。例如熟知的租车服务,互联网上存在众多诸如滴滴、美团、神州及一嗨等服务商提供的租车Web服务接口,经过时间的推移及流行趋势,用户跟风逐流忽视了服务质量的考虑,大多都选择了传统主流的租车服务,导致一些新兴的服务质量较高的服务接口很难被用户所察觉,这就是服务流行度失衡^[17]造成的用户选择单一化的体现。为了避免这种情况,使Web服务多元化发展,需基于用户在线行为数据进行服务流行热度值的评估。

针对用户在线行为,基于服务被调用数量的增长率变化来调整服务流行热度值 p_i 。相对于其他流行性评判的标准,本模型不再关注单位时间内服务被选择调用的数量值大小,而关注的是单位时间内服务被选择的增长速率大小的变化趋势,这就要求首先要描述Web服务 S_i 被调用的数量增长以及其增长速率。经研究发现采用Logistic曲线和种群增长速率曲线可以形象地描述服务 S_i 的用户在线行为数据的变化趋势,服务 S_i 某时间段内被调用数量变化大致与Logistic曲线相似,如图2所示。其中,在某段时间内服务 S_i 被调用数量处于 $a \sim c$ 阶段时,总数量增长速率的斜率为

正,呈上升趋势;处于 $c \sim d$ 阶段时,总数量增长速率的斜率为负,其被用户调用呈下降趋势,而服务 S_i 被调用增长速率变化大致可表现为图3曲线。

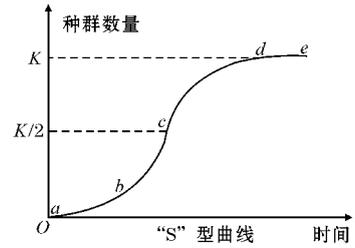


图2 种群增长数量曲线

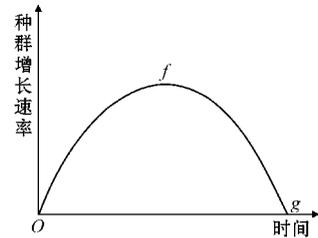


图3 种群增长速率曲线

对于服务 S_i 而言,图3中 f 点增长速率最大,对应图2中 c 点,表明此时处于被用户选择最活跃的时期,亦是流行热度最高的时期;图3中 g 点为增长速率最小点,对应图2中的 d 点之后,服务 S_i 随两曲线描述流行热度变化表现为:服务 S_i 被调用数量处于 $a \sim c$ 阶段,其增长速率处于 $o \sim f$ 阶段,流行热度增强;服务 S_i 被调用数量处于 $c \sim d$ 阶段,其增长速率处于 $f \sim g$ 阶段,流行热度下降。

从上述描述可知,单位时间内Web服务增长速率的斜率发生改变,即意味着服务 S_i 流行热度需自适应动态改变。

2.2 算法模型求解

流行热度的评估涉及最重要的数据即为用户请求时间及空间数据,以用户 U_i 与服务 S_i 的请求交互数据集来表示。

定义5 用户与服务交互数据。二者的一次交互可以看作 U_i 与 S_i 的一次成功合作,记为: $coop(t, s, p_i)$, t, s 分别表示用户 U_i 对服务 S_i 请求的时间、空间位置坐标数据,服务 S_i 所有被调用时的数据集表示为一个矩阵 $M_i, p_{i,m}$ 为服务 S_i 第 m 次数据记录时的流行热度值:

$$M_i = \begin{bmatrix} t_1 & s_1 & p_{i,1} \\ t_2 & s_2 & p_{i,2} \\ \dots & \dots & \dots \\ t_m & s_m & p_{i,m} \end{bmatrix} \quad (8)$$

定义6 服务流行热度 P_i 。作为模型QoS评估的

一项重要属性指标 P_i , 为便于计算, 形式上以一个四元组表示为 $P_i = (c_{pre}, t_{pre}, c_i, t_i)$, 其中 c_{pre} 表示评估前一次该服务 S_i 使用量总值, t_{pre} 为前一次的服务被调用时间, c_i 表示评估时该服务使用总量, t_i 则为被调用时间。

依照用户在线行为造成的服务 S_i 单位之间内使用量的变化, 结合上述基本假设与描述, 利用 Logistic 曲线构造算法来描述单位时间内服务使用量的变化趋势, 流行热度值随服务使用量的增长速率的增减动态改变, 当其增长速率呈上升趋势时, 流行热度值随时间增长函数增加; 当其增长速率呈下降趋势时, 流行热度值随遗忘函数递减。对于流行热度值的增长与衰减我们采用“牛顿冷却定律”的思想并加以改进^[18], 服务流行热度值评估算法具体流程如下:

步骤一 输入: $P_i = (c_{pre}, t_{pre}, c_i, t_i)$ 。

步骤二 计算服务 S_i 在 Δt 固定大小时间段内的服务量增长速率 $GrowthRate_i$:

$$GrowthRate_i = \frac{c_i - c_{pre}}{\Delta t} \quad (9)$$

其中 $\Delta t = t_i - t_{pre}$ 。

步骤三 计算在 t_i 时刻后, 服务 S_i 的增长速率 $GrowthRate_i$ 的斜率 grs :

$$grs = (GrowthRate_i)' = \frac{d(GrowthRate_i)}{dt} \quad (10)$$

步骤四 设全局服务增长速率最大点处如图 3 所示 f 点对应如图 2 所示 $\frac{k}{2}$ 处, 令其记为 $f = GrowthRateMax$, 需遍历所有服务 S 的训练数据集, 找出所存在的 f 普遍最大值, 过程如下:

令 $f = 0$

for ($i = 1; i \leq n; i++$)

{

找出 S_i 在其每个 Δt 内的 $GrowthRate_i$ 最大值,

令

$f_i = GrowthRate_i$

if $f_i > f$

则 $f = f_i$

}

end

步骤五 设每项服务 S_i 的初始 P_i 为 $\frac{f}{2}$ 处, 记为 p_f , 记流行热度计算公式为

$$p = F(k) = \left| \frac{k}{f} \right| \times 10 \quad (11)$$

则 $p_f = F(\frac{f}{2})$ 。

步骤六 若服务 S_i 新发布上线, 则可解决其流行热度冷启动问题, 令其 $P_i = P_f$ 。

步骤七 每 T 个时间段, 进行一次 P_i 计算评估:

for ($i = 1; i \leq n; i++$)

{ 对于 S_i :

(i) S_i 初始化新发布时:

WHILE 在 t_i 时刻, 增长速率 $GrowthRate_i < \frac{f}{2}$, grs

> 0 且 $F(GrowthRate_i) < P_i$ 时

THEN 下调 P_i , 开启 P_i 随时间衰减函数, 则

$$P_i = P_i \times f(|t_i - t_{pre}|) \quad (12)$$

$f(|t_i - t_{pre}|)$ 为时间衰减函数, 其形式为

$$f(|t_i - t_{pre}|) = \frac{1}{e^{\alpha \times |t_i - t_{pre}|}} \quad (13)$$

α 为衰减因子, 令 $\alpha = |grs|$

UNTIL $F(GrowthRate_i) = P_i$, 记此时增长速率为

f_p

END

(ii) IF 在 t_i 时刻, 增长速率 $GrowthRate_i < \frac{f}{2}$ 且

$grs > 0$ 时

THEN 上调 P_i , 开启 P_i 随时间增长函数, 则

$$P_i = P_i \times g(|t_i - t_{pre}|) \quad (14)$$

$g(|t_i - t_{pre}|)$ 为时间增长函数, 其形式为

$$g(|t_i - t_{pre}|) = 1 + \left(1 - \frac{1}{e^{\beta \times |t_i - t_{pre}|}} \right) \quad (15)$$

β 为递增因子, 令 $\beta = |grs|$

(iii) IF 在 t_i 时刻, 增长速率 $GrowthRate_i \geq \frac{f}{2}$ 且

$grs > 0$ 时

THEN 上调 P_i , 开启 P_i 随时间增长函数, 则

$$P_i = P_i \times g(|t_i - t_{pre}|) \quad (16)$$

$g(|t_i - t_{pre}|)$ 为时间增长函数, 其形式为

$$g(|t_i - t_{pre}|) = 1 + \left(1 - \frac{1}{e^{\beta \times |t_i - t_{pre}|}} \right) \quad (17)$$

β 为递增因子, 令 $\beta = |grs|$

(iv) IF 在 t_i 时刻, 增长速率 $GrowthRate_i \geq \frac{f}{2}$ 且

$grs < 0$ 时

THEN 下调 P_i , 开启 P_i 随时间递减函数, 则

$$P_i = P_i \times f(|t_i - t_{pre}|) = \frac{1}{e^{\alpha \times |t_i - t_{pre}|}} \quad (18)$$

(v) IF 在 t_i 时刻, 其增长速率 $GrowthRate_i = f = GrowthRateMax$ 且 $grs = 0$ 时

THEN $P_i = F(f)$

(vi) IF 在 t_i 时刻, 增长速率 $GrowthRate_i < \frac{f}{2}$ 且

$grs < 0$ 时

THEN 下调 P_i , 开启 P_i 随时间递减函数, 则

$$P_i = P_i \times f(|t_i - t_{pre}|) = \frac{1}{e^{\alpha \times |t_i - t_{pre}|}} \quad (19)$$

}

Return P_i

步骤八 输出 P_i 值。

2.3 空间条件量化方法

对于传统的 Web 服务而言, 推荐也大多依赖于空间距离的远近, 都是根据用户 U_i 与服务 S_i 实际物理距离来进行空间量化计算并推荐, 而这也忽略了广大用户的普遍选择对个体选择的影响, 也就是未能考虑用户群体请求服务的空间位置变化等此类在线行为。而我们把用户对于服务 S_i 的请求进行区域划分, 找出服务 S_i 的热点地域, 直观看来就是服务请求位置集中和密度大的区域。对于服务 S_i , 该服务的用户请求位置密度随用户在线行为不断变化, 以用户请求密度最高点来确定服务 S_i 的热点中心, 通过评估用户 U_i 与各服务热点中心的距离作为其虚拟量化距离以代替普遍使用的实际量化距离, 并可利用该距离评估数据源 U_i 给予的流行热度 p_i 数据。

由定义 5 可知数值对矩阵 $\mathbf{M}_i = [t_m \quad s_m \quad p_{i,m}]$ 中记录了调用服务 S_i 的用户空间位置数据, 遍历 T 时段内所有的位置数据 s_m , 通过位置聚类^[19], 找出离所有位置坐标点距离之和最小的位置坐标作为整个服务 S_i 的热度中心, 记为 H , 用户 u_i 的请求位置与热点中心 H 的距离即为 u_i 对于 S_i 的评估距离, 通过距离评估 $u_{p,i}$, 则 T 时段内用户请求密度评估算法流程如下。

输入: 矩阵 \mathbf{P}_i

令两位置经纬坐标点分别记为 $[lon_1, lat_1], [lon_2, lat_2]$, 之间的距离采用统一标准计算:

$L = \arcsin$

$$\sqrt{\left[\sin\left(\frac{lat_1 - lat_2}{2}\right)\right]^2 + \cos(lat_1) \times \cos(lat_2) \times \left[\sin\left(\frac{lon_1 - lon_2}{2}\right)\right]^2}$$

则

$$|s_i - s_j| = 2R \times L \quad (20)$$

其中 R 为地球半径。

(i) 遍历并找出 \mathbf{P}_i 矩阵中属于时段 T 内的时刻 t 集合

令 $T \in [(m-1) \times t_k, m \times t_k], m = 1, 2, \dots, n$

定义一个集合 \mathbf{P}_n

for ($i = 1; i \leq m; i++$)

IF ($(m-1) \times t_k \leq t_i \leq m \times t_k$)

$\mathbf{P}_n = \mathbf{P}_n + coop_i$

Return \mathbf{P}_n

(ii) 经位置聚类找出服务 S_i 热点中心

遍历 \mathbf{P}_n 中所有 m 个请求交互中的位置点, 找出相互之间最小距离和的坐标点, 表示为

$$s_m = \sum_{j=1}^m |s_1 - s_j| \quad (21)$$

for ($i = 1; i \leq n; i++$)

}

$$s_i = \sum_{j=1}^m |s_i - s_j|$$

IF ($s_i < s_m$)

THEN $s_m = s_i$

$k = i$

}

返回热度中心点 s_k

Return s_k

(iii) 对热度中心点 s_k 和所有 m 个点的距离 L 从小到大进行排序:

$$l = \sum_{j=1}^m \text{sort}(s_k - s_j) \quad (22)$$

其中 l 表示距离数组集合, 令 l 数组中最小距离数值为数组头 l_1 ; 最大距离数值为数组尾 l_{m-1} , 则用户 u_i 在该时刻 T 内的请求位置 s_i 与 s_k 的距离占 $s_k \sim s_{m-1}$ 距离的比例即为其提供的热度值数据 $u_{p,i}$ 。则令该比例为

$$\text{prop}_s = \left| \frac{s_i - s_k}{s_k - s_{m-1}} \right| \quad (23)$$

IF $\text{prop}_s > 1$

$u_{p,i} = 0$

ELSE

$u_{p,i} = (1 - \text{prop}_s) \times 10$

Return $u_{p,i}$

输出: 服务 S_i 热度中心点 s_k , 数据源 u_i 提供的数据 $u_{p,i}$ 。

3 QoS 动态合成及归一化评估方案

据前述定义可知, 文中所描述的是一种由服务商 P 公布的数据、网络检测 M 的数据以及用户评价行为 U 的数据 3 个数据源以及可靠性 r_i 、时效性 t_i 、服务价格 c_i 、安全性 s_i 、适应性 ad_i 、流行性 p_i 6 个属性所构成的多数据源多属性集成的 QoS 动态评估模型, 需要对 QoS 属性的组成、表示和计算按一定的规范化算法和评价标准合成综合评价值。首先对属性值误差进行评估, 将各属性作为随机变量来处理, 使用期望和方差来度量各个属性值, 其次根据 QoS 各属性量纲不同, 进行归一化, 并通过改进误差动态加权方法对数据进行

合成^[12]。

3.1 各属性误差评估

用期望和方差衡量各个属性的具体值,保证数据不受噪声及随机因素的影响。令服务 S_i 被用户请求调用一次成功完成服务后,使该服务 S_i 的 QoS 某项属性 x_i 实际结果看作一个随机变量 X ,设 $E(X)$ 、 $D(X)$ 为服务 S_i 被请求调用前的期望和方差,设 $E(X)$ 、 $D(X)$ 都存在,若计算方差为 0,则证明本次数据不存在误差,否则由切比雪夫定理(chebyshev's theorem)^[20]可知,对于 $\forall \varepsilon > 0$, $\exists P\{|X-E(X)| \geq \varepsilon\} \leq \frac{D(X)}{\varepsilon^2}$ 成立,则其概率为该随机变量 X 的置信概率为 $\gamma = \frac{D(X)}{\varepsilon^2}$,置信范围为: $[E(X) -$

$$\sqrt{\frac{D(X)}{\gamma}}, E(X) + \sqrt{\frac{D(X)}{\gamma}}]$$

(i) 为 γ 统一设定为一个置信概率数值 β , 则

$$\frac{D(X)}{\varepsilon^2} = \beta, \varepsilon = \sqrt{\frac{D(X)}{\beta}}$$

(ii) 遍历该服务 S_i 历史数据 $list$ 判断其值是否在置信范围之内, $x \in list$, 令历史数据的总数量为 t , n 为记录在置信区间内的数据数量:

for ($i=0$; $i<t$; $i++$)

{
IF $x \in [E(X) - \sqrt{\frac{D(X)}{\gamma}}, E(X) + \sqrt{\frac{D(X)}{\gamma}}]$,

$n++$

}

WHILE $\frac{n}{t} < \varepsilon$ 时

THEN 线性递增 β 的值, 并重新计算 $\varepsilon =$

$$\sqrt{\frac{D(X)}{\beta}}$$

UNTIL $\frac{n}{t} \geq \varepsilon$ 时, 则记录此时的 ε 值

(iii) 判断该次的数据 x_i 是否在误差范围内

IF $x_i \in [E(X) - \sqrt{\frac{D(X)}{\gamma}}, E(X) + \sqrt{\frac{D(X)}{\gamma}}]$, 即证

明该随机变量 X 在误差范围内, 则不更新 $E(X)$ 、 $D(X)$

Return x_i

ELSE 把本次数据插入进历史数据 $list$, 根据最近 n 次结果再次对 $E(X)$ 、 $D(X)$ 进行更新, 将 $E(X)$ 作为该属性结果 $x_i = E(X)$

Return x_i

3.2 数据归一化

由于 3 个数据源所提供的 QoS 各属性描述存在差异, 其评估量纲也不同, 要实现之后 3 个数据源动态合成, 使用归一化对数据进行处理, 简化了计算, 将有量纲的数据经过变换转化为无量纲的数据, 使数据映射到 $[0, 1]$ 区间内。采用普遍常见的改进型 z -score 归一化方法, 设服务 S_i 的某项 QoS 属性在同一时刻取值集合为 $x = \{x_1, x_2, x_3, \dots, x_n\}$, 令 S_i 在该时刻执行后取值

为 X_i , 则归一化为: $X_i = \frac{x_i - \bar{x}}{\sigma_a}$, 其中 $\bar{x} = \frac{\sum_{i=1}^n x_i}{n}$, $\sigma_a = \sqrt{\frac{\sum_{i=1}^n |x_i - u|^2}{n}}$, u 为均值或中位数。

3.3 各数据源的数据加权合成

为避免服务商 P 及用户 U 制造的虚假数据, 影响服务质量的客观评估, 在 3 个数据源加权合成的过程中使用一种改进后的误差评估动态加权算法^[12], 算法使 3 个数据源中任何一个与其余两个平均值偏离过大时, 改变其权值分配, 否则恢复其权值分配, 从而避免噪声数据带来的影响。设 $f_i \in q_i$, 则 $f_i = (p_{f,i}, m_{f,i}, u_{f,i})^T$, 将属性 f_i 加权合成记为

$$D(f_i) = \varphi_p \times p_{f,i} + \varphi_m \times m_{f,i} + \varphi_u \times u_{f,i} \quad (24)$$

其中 φ_p 、 φ_m 、 φ_u 为 P 、 M 、 U 的权值。该数据源误差动态评估加权算法流程为: 设 a_1 、 a_2 、 a_3 为 $\{p_{f,i}, m_{f,i}, u_{f,i}\}$ 中随机分配的 3 个数据值, φ_1 、 φ_2 、 φ_3 为 $\{\varphi_p, \varphi_m, \varphi_u\}$ 中随机分配的权重, 下标相同的数值与权重一一对应。

输入: f_i

初始化: $\varphi_1 = c_1$, $\varphi_2 = c_2$, $\varphi_3 = c_3$ 且 $c_1 + c_2 + c_3 = 1$ 。

计算每个各数据源数据的变化增长率, 记为

$$c_i = (a_i - a_{pre}) / a_{pre} \quad (25)$$

根据各数据源提供数据的变化增长率的大小分配权重, 权重与数据呈线性正相关。

对于任意数据值 a_i $i \in \{1, 2, 3\}$ 与其他两个数据值平均的差:

如 $i=1$

IF $\left| a_1 - \frac{(a_2 + a_3)}{2} \right| > \delta, \delta \in \left[\frac{1}{2}, 1 \right)$

THEN $\varphi_1 = \min\{c_1, c_2, c_3\}$

$$\max\{\varphi_1, \varphi_2, \varphi_3\} = \max\{c_1, c_2, c_3\}$$

ELSE IF $\left| a_1 - \frac{(a_2 + a_3)}{2} \right| < \varepsilon$ ($\varepsilon < \delta$) 且 $\varphi_1, \varphi_2, \varphi_3$ 对

应的权值改变过, 即为 $\varphi_1 \neq c_1, \varphi_2 \neq c_2, \varphi_3 \neq c_3$

THEN $\varphi_1 = c_1, \varphi_2 = c_2, \varphi_3 = c_3$

Return $[\varphi_1, \varphi_2, \varphi_3] \times f_i$

3.4 多 QoS 属性集成

由于 $f_i \in q_i$, 则 6 个属性合成值分别为: 可靠性 $D(r_i)$ 、时效性 $D(t_i)$ 、价格 $D(c_i)$ 、安全性 $D(s_i)$ 、适应性 $D(ad_i)$ 、流行性 $D(p_i)$, 采用文献[12]中的集成方法并结合文中定义的 QoS 属性, 把数据分为与综合评估值增长成正相关和负相关两类, 将服务综合评价值记为 $integr(S_i)$, 则 QoS 综合评价公式为

$$integr(S_i) = \frac{D(r_i) \times D(ad_i) \times D(p_i)}{D(t_i) \times D(c_i) \times D(s_i)} \quad (26)$$

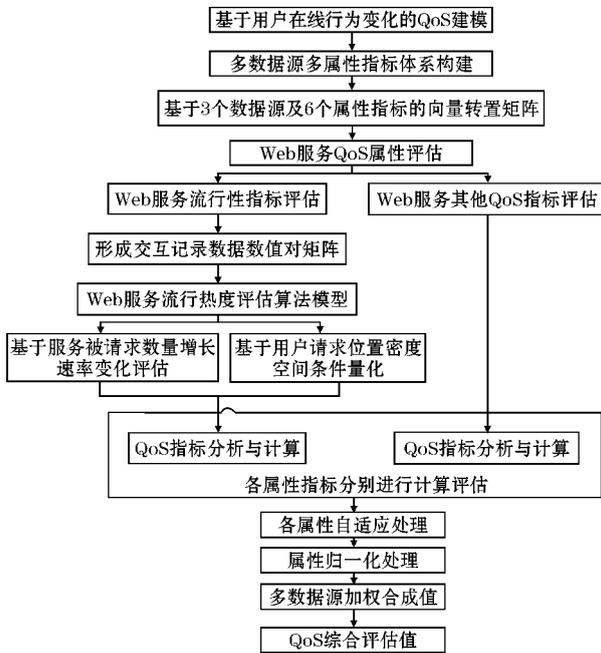


图4 Web 服务 QoS 模型评估框架

综上所述, 基于用户在线行为变化所造成 Web 服务 QoS 数据随时间动态改变, 构建了 Web 应用服务 QoS 动态评估模型, 如图 4 所示。首先采用了一种多数据源提供多属性指标的评估方案^[12], 基于 3 个数据源提供 6 个 QoS 属性的体系, 进而确立了转置向量的表示形式, 然后对各属性指标计算进行了具体的定义与评估, 其中定义的流行性属性指标能深刻的体现用户在线行为的变化规律, 并构建了服务流行热度值评估算法模型, 通过单位时间内 Web 服务被请求数量的增长速率变化来评估网络监测数据源提供的流行热度值; 通过单位时间内用户请求位置密度变化, 构造空间条件量化算法来评估用户数据源提供的流行性数据, 从而能够基于用户不同时间与空间在线行为对 Web 服务流行性进行评估。同时对 QoS 属性数据自适应及归一化处理, 并对数据源加权合成, 形成最终的 QoS 综合评价值。

4 仿真实验与分析

通过仿真实验来验证动态环境下文中所设计的评估模型的有效性, 动态环境的场景数据基于用户的在线行为数据的不断变化, 实验采用的数据均来自于爬虫互联网上的公共 Web 服务数据, 选取了其中 5 项同类 Web 服务数据用作实验对比验证, 数据集提供的数据均为服务商、用户及网络检测的直接数据, 其中用户在线行为数据体现在用户与服务交互的量值, 包括用户的请求时间、位置等数据, 并设计了实验场景证明评估模型的有效性, 实验结果分析见表 1。

表1 Web 服务流行度评估值

WS	round ₁	round ₂	round ₃	round ₄	round ₅	round ₆	round ₇	round ₈	round ₉	round ₁₀
WS ₁	5.0	2.46	1.1627	1.2264	1.3777	2.5593	1.6369	0.6467	1.2933	1.5918
WS ₂	5.0	2.45	1.1882	1.1954	1.0912	2.1037	1.3306	0.5302	1.0605	1.3022
WS ₃	5.0	2.43	1.1644	1.2812	1.1138	2.1351	1.4554	0.5681	1.1361	1.4626
WS ₄	5.0	2.48	1.1973	1.1228	1.0449	2.0134	1.3389	0.5313	1.0605	1.3208
WS ₅	5.0	2.47	1.1807	1.2613	1.2351	2.3321	1.5874	0.6178	1.2355	1.5308

根据所阐述设计的服务流行热度评估算法模型, 以天为单位对 5 项服务 WS₁ ~ WS₅ 进行了评估实验, 实验数据集记录了各单位时间内各项服务的用户在线行为数据, 共采取了其中 10 次评估数据, 实验结果如表 1 所示, WS₁ ~ WS₅ 的服务流行性处于一个动态变化的状态, 表明服务流行的热度值能够随不同时刻用户行为变化而动态调整。

如实验数据所示, round₁ 数据都为显示为 5.0, 即为服务流行性初始化计算值, 由表 2 实验数据可知, 虽然 round₂ 用户行为数据量相对于 round₁ 大大提升, 增长速率也随之较大增长, 但各服务的流行热度值也都实现了下调, 验证了算法能够感知服务冷启动后流行热度值比实际水平较高, 从而进行回调至相对合理的数值。针对 WS₁ 和 WS₅ 的评估数据进行比较, round₁₀

中 WS_1 的用户行为数据量为 563, 在所有服务中增长量为最低的, WS_5 的用户行为数据量为最高的 710, 且后者的服务总量明显高于前者, 但前者流行性为 1.5918, 后者则相对其较低为 1.5308, 证明了该算法模型并不是以历史服务总量以及本次服务总量来衡量该段时间内服务的流行热度, 而考虑的是单位时间之间用户的在线行为数据, 导致服务总量变化率的增减, 如

表 2 Web 服务增长量值

WS	round ₁	round ₂	round ₃	round ₄	round ₅	round ₆	round ₇	round ₈	round ₉	round ₁₀
WS_1	445	1250	302	319	361	1065	589	42	446	563
WS_2	430	1193	327	329	299	1085	588	47	440	570
WS_3	458	1157	306	338	291	1015	626	37	472	632
WS_4	429	1211	327	306	284	1027	608	46	430	570
WS_5	509	1409	373	400	391	1248	768	44	558	710

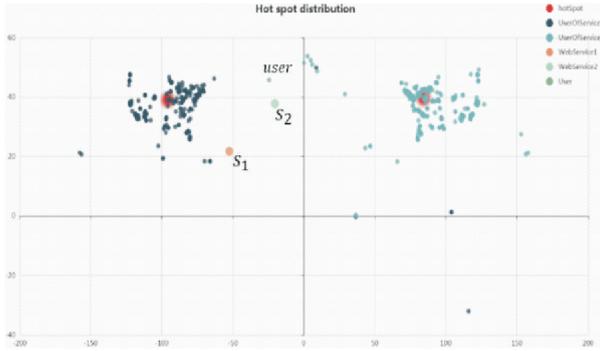


图 5 用户在线位置散点图

根据前文所描述的用户请求密度空间量化方法模型, 分析 $round_{10}$ 阶段 WS_1 与 WS_3 的用户请求位置密度评估服务热点中心, 如图 5 用户请求位置散点图, 其中横坐标表示地理位置经度, 纵坐标表示纬度, 展示了两服务的用户请求位置分布, 并准确的计算出两服务热点中心位置, 由实验计算可知, 用户 $user$ 与 S_1 距离为 3684.367, 与 S_2 的距离为 950.103, 明显可知前者大于

$round_9$ 时刻, WS_2 与 WS_4 流行性都变化为了 1.0605, 且在 $round_{10}$ 阶段两服务增长量值相同, 但流行性 $P_4 > P_2$, 因为 WS_4 的增长量值相对于上阶段评估的增长率高于 WS_2 , 验证了本算法能够正确的以服务增长速率的变化趋势为基础进行动态调控, 体现了该流行度评估算法模型的优越性, 解决了传统流行度评估时所造成的流行度失衡以及结果偏一化的问题。

后者, 但 $user$ 与 S_1 的热点中心 $[-95.6890185, 39.0558235]$ 的距离为 5709.497, 与 S_2 的热点中心 $[84.2677515, 39.6155668]$ 的距离为 8175.428, 且 $user$ 与 S_1 的流行性交互评估值为 8.5207, 与 S_2 的评估值为 5.5107, 即证明该算法根据用户在线行为的位置进行密度划分后能正确找出热点中心并根据用户与热点中心的距离进行评估, 验证了该算法的可行性。

对于每轮数据所设计和改进的误差评估算法, WS_1 在 $round_4$ 阶段选取 2 个属性的 4 轮评估值如表 3 所示, 其中 evaluate 为误差评估后的数据, 经过误差评估算法的分析后得出 ε 值, 可靠性的第 4 轮评估数值在本次置信区间范围内, 固保留原数据 0.3343, 而 UPopularity 属性的第 4 轮评估数值与前三轮比相对较小, 明显低于历史数据, 固调高本次评估值为 8.7081, 使数据更加合理, 证明了该算法能够自适应发现误差噪声数据并进行及时调整。

表 3 属性评估数据

Attribute	evaluate	round ₁	round ₂	round ₃	round ₄
Reliability	0.3384	0.3461	0.3344	0.3343	0.3343
UPopularity	8.8442	8.8409	8.8782	8.2689	8.7081

对于文中所描述的 3 个数据源的数据加权合成算法, WS_1 在 $round_9$ 阶段服务商 P 、监测数据 M 以及用户数据 U 经过计算所评估的数据分别为 0.6672、0.6672、0.3633, 相比于 $round_8$ 阶段, 其中 P 和 M 的增长率相对较大, 且任意数据源的数据与其他两数据差值未超过 δ , 固 P 和 M 在加权时分配到相对较大的两个权值, U 则分配到了较小的权值, 证明了动态加权的

有效性, 各数据源对各属性的一次总体评估数据如表 4 所示, 由多次实验证明所描述的多数据源多评估指标的动态 QoS 评估算法模型能够有效评估各属性, 并合理进行误差和归一化评估以及动态加权合成, 可执行性较高, 能够为各服务提供 QoS 综合评估值, 保证了数据的真实性和可靠性。

表4 评估实验结果

	reliability	timeLiness	servlcePrice	security	popularity	adaptive	QosIntegration
WS ₁	0.3144	0.5605	0.5	0.5	0.5760	0.3328	0.430
WS ₂	0.4564	0.3196	0.5	0.5	0.4791	0.6169	1.696
WS ₃	0.7716	0.6551	0.5	0.5	0.4804	0.5265	1.192
WS ₄	0.4584	0.5646	0.5	0.5	0.3846	0.6172	0.771
WS ₅	0.4992	0.4001	0.5	0.5	0.5799	0.4039	1.169

5 结束语

通过分析用户的在线行为所造成的 Web 服务流行度失衡及流行热度的区域性变化导致服务质量评估缺乏准确性和实时性,重构了多数据源和多属性集成的动态 QoS 评估模型。模型在传统 QoS 属性的基础上,重新定义了各指标的计算方法,增加了对用户在线行为可描述性较高的流行性作为评估的重要指标,优化以往用浏览或评论的数量衡量服务流行热度的方法,形成了服务流行热度值评估算法模型,能动态调整区域时间内服务请求数量增长率变化所造成的流行热度的改变,同时基于聚类思想,提出了服务请求热点位置密度划分的量化方法,体现用户在线行为导致时间与空间数据的动态改变,最后阐述了 QoS 动态合成及归一化算法和整体评估框架。文中所阐述的模型和求解算法都是针对用户与服务交互所产生的历史及实时记录数据进行分析与计算,具有较强的操作性,未来工作还需将其注入推荐系统中对模型及算法进行进一步的实验研究与改进。

参考文献:

- [1] 周春华,沈建京,李艳,等. 经典推荐算法研究综述[J]. 计算机科学与应用,2019,9(9):1803-1813.
- [2] Eszter Hargittai. Whose Data Traces, Whose Voices Inequality in Online Participation and Why it Matter for Recommender Systems Research [EB/OL]. <https://recsys.acm.org/wp-content/uploads/2019/09/recsys-19-keynote-2>,2019.
- [3] 许弘杰. 基于用户特征与强化学习的商品推荐算法[D]. 广州:华南理工大学,2019.
- [4] 冯康. 基于用户行为的电影推荐系统的设计与实现[D]. 淮南:安徽理工大学,2018.
- [5] 陈晓璇,刘洪伟,曹宁. 基于用户在线行为的个性化推荐研究[J]. 合作经济与科技,2018(7):86-87.
- [6] 沈婧. 基于在线系统的用户兴趣模型与个性化推荐[D]. 深圳:深圳大学,2018.
- [7] 李斌,张博,刘学军,等. 基于 Jaccard 相似度和位置行为的协同过滤推荐算法[J]. 计算机科学,2016,43(12):200-205.
- [8] 孙亚利. 基于用户行为的移动电子商务推荐算法研究[D]. 镇江:江苏大学,2017.
- [9] Elsayed D. PGAQK: An adaptive QoS-aware Web Service Composition approach [J]. International Journal of Intelligent Engineering & Systems, 2018,11(4):231-240.
- [10] V X Tran, H Tsuji. A Survey and Analysis on Semantics in QoS for Web Services [C]. International Conference on Advanced Information Networking and Applications, Bradford. IEEE, 2009:379-385.
- [11] Bharadwaj D, Tripathi A, Agrawal A, et al. Analysis of Users Behavior on Micro-blogging Site Using a Topic [M]. Advanced Machine Learning Technologies and Applications, 2021.
- [12] 张亚光. 智能软件服务关键技术研究[D]. 北京:中国电子科学研究院,2013.
- [13] Zheng H Y, Yang J, Zhao W, et al. QoS Analysis for Web Service Compositions Based on Probabilistic QoS [J]. Service-Oriented Computing-9th International Conference, Paphos, Cyprus, December 5-8, 2011 Proceedings. Springer Berlin Heidelberg. ICSOC, 2011, 7084:47-61.
- [14] Chen L, Yang J, Zhang L. Time Based QoS Modeling and Prediction for Web Services [J]. Service-Oriented Computing-9th International Conference, Paphos, Cyprus, December 5-8, 2011 Proceedings. Springer Berlin Heidelberg. ICSOC, 2011, 7084:532-540.
- [15] 陈云翔,张净敏,项华春,等. 基于比例失效率退化模型的可靠性评估方法[J]. 系统工程与电子技术,2015,37(8):1943-1947.
- [16] 曹继承. 基于 QoS 的 Web 服务推荐算法研究

- [D]. 南京:南京邮电大学,2018.
- [17] 战凯. 基于遗忘函数和项目流行度的推荐算法研究[D]. 银川:北方民族大学,2017.
- [18] 李健,曲卫芬. 众包中基于博弈论的牛顿冷却定律应用[J]. 青岛大学学报(自然科学版), 2020,33(1):39-46.
- [19] 邹臣嵩,杨宇. 基于最大距离积与最小距离和协同 K 聚类算法[J]. 计算机应用与软件, 2018,35(5):297-301,327.
- [20] Ianoi D, Opri A A. On some inequalities relative to the Pompeiu-Chebyshev functional[J]. Journal of Inequalities and Applications, 2020(46):1-20.

A Dynamic QoS Evaluation Method for Web Services based on Online Behavior Analysis of Users

WANG Ruixiang, WEI Le, CHANG Yu, DUAN Yanfei

(College of Software Engineering, Chengdu University of Information Technology, Chengdu 610225, China)

Abstract: As the computer-centric web service provision method is changing to the user-centric web service provision method, considering that the previous dynamic QoS model fails to fully consider the online behavior of users and other factors, which leads to the lack of real-time accuracy of service quality assessment. For this reason, this article considers factors such as the imbalance in the popularity of web services and the regional changes in popularity caused by user online behaviors, establish an algorithm model for the evaluation of service popularity, the idea of Logistic growth curve and population growth rate curve was used to describe the changes of users' online behaviors. And based on the forgetting algorithm, the service popularity heat value evaluation algorithm is proposed, which can adaptively adjust the popularity value according to the change trend of the growth rate of the number of service requests per unit time, the clustering algorithm is used to divide the hotspot location density of service requests, which solves the problem of regional changes in popularity. Then the popularity is regarded as an important indicator of the dynamic QoS model, and the model is reconstructed and adjusted, through the establishment of data error evaluation, normalization and dynamic weighting, the dynamic synthesis of QoS attributes is realized. Finally, experiments verify that the model is feasible and effective.

Keywords: Web services; service quality; popularity; online behavior; QoS modeling