

多元时间序列的 Web Service QoS 预测方法^{*}

张鹏程¹, 王丽艳¹, 吉顺慧¹, 李雯睿²

¹(河海大学 计算机与信息学院, 江苏 南京 211100)

²(南京晓庄学院 信息工程学院, 江苏 南京 211171)

通讯作者: 张鹏程, E-mail: pchzhang@hhu.edu.cn

摘要: 为准确并多步预测 Web 服务的服务质量(quality of service, 简称 QoS), 方便用户选择更好的 Web 服务, 提出了一种基于多元时间序列的 QoS 预测方法 MulA-LMRBF(multiple step forecasting with advertisement-levenberg marquardt radial basis function). 充分考虑多个 QoS 属性序列之间的关联, 采用平均位移法(average dimension, 简称 AD)确定相空间重构的嵌入维数和延迟时间, 将 QoS 属性历史数据映射到一个动力系统中, 近似恢复多个 QoS 属性之间的多维非线性关系。将短期服务提供商 QoS 广告数据加入数据集中, 采用列文伯格-马夸尔特法(Levenberg-Marquardt, 简称 LM)算法改进的径向基(radial basis function, 简称 RBF)神经网络预测模型, 动态更新神经网络的权重, 提高预测精度, 实现 QoS 动态多步预测。通过网络开源数据和自测数据的实验结果表明, 该方法与传统方法相比有较好预测效果, 更适合动态多步预测。

关键词: 服务质量; 多元时间序列; 相空间重构; LM 算法; RBF 神经网络; 动态多步预测

中图法分类号: TP311

中文引用格式: 张鹏程, 王丽艳, 吉顺慧, 李雯睿. 多元时间序列的 Web Service QoS 预测方法. 软件学报, 2019, 30(6):1742–1758.
<http://www.jos.org.cn/1000-9825/5425.htm>

英文引用格式: Zhang PC, Wang LY, Ji SH, Li WR. Web service QoS forecasting approach using multivariate time series. Ruan Jian Xue Bao/Journal of Software, 2019, 30(6):1742–1758 (in Chinese). <http://www.jos.org.cn/1000-9825/5425.htm>

Web Service QoS Forecasting Approach Using Multivariate Time Series

ZHANG Peng-Cheng¹, WANG Li-Yan¹, JI Shun-Hui¹, LI Wen-Rui²

¹(College of Computer and Information, Hohai University, Nanjing 211100, China)

²(School of Information Engineering, Nanjing Xiaozhuang University, Nanjing 211171, China)

Abstract: In order to accurately forecast quality of service (QoS) of different Web services with multi-step, and help users to choose the most suitable Web service at hand, this study proposes a novel QoS forecasting approach called MulA-LMRBF (multiple-step forecasting with advertisement by levenberg-marquardt improved radial basis function network) based on multivariate time series. Considering the correlation among different QoS attributes series, phase-space reconstruction is used to map historical multivariate QoS data into a dynamic system, where the multi-dimensional nonlinear relations of QoS attributes are completely restored. Average dimension (AD) is used to estimate the embedding dimension and delay time of reconstructed phase space. The short-term QoS advertisement data of service provider is also added to form a more comprehensive data set. Then, RBF (radial basis function) neural network improved by the Levenberg-Marquardt (LM) algorithm is used to update the weight of the neural network dynamically, which improves the forecasting accuracy and realizes the dynamic multiple-step forecasting. Experiments are conducted based on several public network data sets and

* 基金项目: 国家自然科学基金(61572171, 61702159, 61202097); 江苏省自然科学基金(BK20170893); 中央高校基本科研业务费(2019B15414)

Foundation item: National Natural Science Foundation of China (61572171, 61702159, 61202097); Natural Science Foundation of Jiangsu Province, China (BK20170893); Fundamental Research Funds for the Central Universities of China (2019B15414)

收稿时间: 2017-02-24; 修改时间: 2017-05-12, 2017-08-17; 采用时间: 2017-10-11; jos 在线出版时间: 2017-12-01

CNKI 网络优先出版: 2017-12-04 08:57:32, <http://kns.cnki.net/kcms/detail/11.2560.TP.20171204.0857.017.html>



self-collected data set. The experimental results demonstrate that MulA-LMRBF is better than previous approaches with high precise and is more suitable for multi-step forecasting.

Key words: quality of service; multivariate time series; phase-space reconstruction; LM algorithm; RBF neural network; dynamic multiple step forecasting

随着 Web 服务技术的快速发展和应用,网络上出现很多功能相似的 Web 服务,在选择满足用户需求的 Web 服务过程中,非功能性需求往往被人们忽视^[1],近几年来,作为非功能性因素的 QoS 逐步被人们重视^[2]。Web 服务由 Internet 网络提供,因为网络环境等因素的变化而受到影响,因此,真实网络的 QoS 具有非线性、动态多变的特点,选择服务前提供有效的服务 QoS 信息显得格外重要^[3,4]。

目前,越来越多的研究人员开始致力于 Web 服务 QoS 预测技术,在服务功能满足用户需求的情况下,为用户选择服务或避免服务故障提供了技术支持。现有的预测模型根据预测技术可以分为基于结构方程(structural equation)的 QoS 预测方法^[5,6]、基于相似度的 QoS 预测方法^[7,8]、基于人工智能的 QoS 预测方法^[9,10]和基于时间序列的 QoS 预测方法^[11]等。

- (1) 基于结构方程的 QoS 预测方法根据 QoS 的过去值分析当前值变化趋势,该方法可以分析属性的内部关系,但不能预测具体值^[5]。Le 等人^[6]根据单个属性历史信息的趋势,提出了一种 QoS 定量预测法,但只能预测属性的变化情况,预测值不准确;
- (2) 基于相似度的 QoS 预测方法是利用使用过该 Web 服务的用户的 QoS,根据相似度预测其他未使用者或该用户使用的其他服务的 QoS^[12]。最早由 Shao 等人^[7,8]提出,使用协同过滤法(collaborative filtering approach),根据用户相似度预测未使用过的服务 QoS。该类方法具有预测模型简单、速度快的特点,但是只能用于单一功能且任务确定的 Web 服务;
- (3) 基于人工智能的 QoS 预测方法具有很强的自适应能力和实时预测能力^[9,10],能够预测复杂的非线性的 QoS 属性值。Liu 等人^[13]提出一种基于 BP(back-propagation)神经网络的 Web 服务 QoS 预测方法,在训练速度、预测精度方面并不完善,大多数模型都存在训练速度慢、时效性差等缺点,并没有很好地发挥智能方法的优点。Fan 等人^[10]提出了一种基于遗传编程(genetic programming,简称 GP)的 QoS 属性预测方法,动态预测 QoS 属性值,预测精度较好,但是预测步长短;
- (4) 基于时间序列的 QoS 预测方法主要利用 QoS 属性的时间维序列构建模型,随时间变化预测未来 QoS 的属性值。该类方法最早用于经济、金融等领域^[14],主要基于 ARIMA(autoregressive integrated moving average)等模型^[15],因为时间序列方法具有精确度相对较高、时效性强的优点,后来逐渐扩展到其他领域,但仍然存在预测周期短、随周期变长误差逐渐变大的缺点。Ye 等人^[16]提出了一种基于多元时间序列的 QoS 长期预测方法,构建了属性关系式,基于 ARIMA 和 Holt-Winters 建立长期预测模型,该方法只适用于静态预测,动态性较差。

根据上述分析,当前 Web 服务 QoS 预测方法存在问题归纳如下。QoS 属性间的相互影响考虑不充分。QoS 属性主要包括响应时间、吞吐量、可靠性、可用性、价格等^[17]。它们之间存在错综复杂的关系。例如:当响应时间变大时吞吐量变小,可扩展性对可靠性也产生影响,属性间的关系无法用准确的公式模型表示^[6],自行构建的关系式往往随着数据样本的改变而发生变动,大部分只针对目标属性的历史数据预测未来值,存在 QoS 属性信息不足的缺点,影响预测周期和准确性;预测步长较小,多步预测效果不好。Web 服务 QoS 的整体发展趋势随服务提供商的策略变化具有动态多变的特性,直接利用目标属性的历史数据做多步直接预测不能保证预测的精确度。对于企业或用户长期使用的 Web 服务,需要多步长预测未来 Web 服务质量,因此,多步预测具有重要的研究意义;动态性差。Web 服务 QoS 属性值具有动态多变的特点,目前,大多数模型根据历史数据建立固定模型,没有考虑随数据的更新、动态改变模型参数,在实际预测中缺乏实用性。

为解决上述问题,本文提出一种新颖的基于多元时间序列的 Web 服务 QoS 预测方法,简称 MulA-LMRBF (multiple step forecasting with advertisement-levenberg marquardt radial basis function)。一方面,对于用户长期使用的 Web 服务,从长远角度预测服务质量;另一方面,单元时间序列包含的非线性系统信息较少,适合短期单步

预测稳定且功能简单的服务。多元时间序列中包含较多的 QoS 信息,相空间(phase space)重构后比单元时间序列包含更多的系统动态信息,因此采用多元时间序列实现 QoS 动态多步预测。总体来说,本文贡献主要包括如下 4 个方面。

- (1) 针对问题 1),考虑 QoS 属性间存在复杂的联系,采用相空间重构方法,将时间序列上每个 QoS 属性历史数据映射到一个动力系统中,近似恢复序列原来的多维非线性系统。重构后的时间序列包含更多 QoS 属性动态信息,属性之间的关联可以通过非线性系统描述,使预测更具动态性和准确性;
- (2) 针对问题 2),因为短期 QoS 广告数据(advertisement data)是根据服务未来的趋势发布,代表当前 QoS 属性值的走向。将模拟生成的短期服务提供商的 QoS 广告数据加入到预测数据集中,辅助实现多步预测,提高预测精度;
- (3) 针对问题 3),利用 LM 算法改进的 RBF 神经网络模型(LMRBF)^[18,19]实现动态预测,该模型以黑盒模式描述输入变量与预测变量之间的复杂关系,利用 LM 最优化算法训练权值,提高运算效率,但是迭代训练权值的运算不够优化。本文进一步优化 LMRBF 方法,减小了时间开销和空间开销,相对准确地预测属性值。针对 QoS 动态多变的特点,每采集一新样本动态更新神经网络的参数值,实现动态预测;
- (4) 在提出方法的基础上,利用开源数据集和自测数据实现相关实验。实验验证了相空间重构和广告数据对预测的影响以及 MulA-LMRBF 方法在多步动态预测中的有效性,与其他方法比较,在预测准确度方面有明显提高。

本文第 1 节介绍方法运用的背景知识和相关的理论基础。第 2 节介绍本文提出的预测方法 MulA-LMRBF。第 3 节给出实验设计和结果分析。第 4 节对本文工作加以总结和展望。

1 预备知识

1.1 相空间重构

非线性时间序列可以看做由确定的非线性系统产生的,相空间是描述系统运动和演变最有力的工具之一,可以表示动力系统中所有可能的状态,其中每个状态具有对应的相位空间点,从而刻画了一个点随时间变化的情况。目前,很多研究人员选择相空间重构(phase-space reconstruction)处理非线性时间序列,近似恢复序列构成的动力系统。相空间重构最早是由 Takens^[20]提出,相空间重构定理认为:系统中任意变量的发展都是由与之相互作用的其他变量决定的,相关变量的信息隐含在其他变量的发展过程中,当选择的嵌入维恰当时就可以重构序列的原系统^[18,21]。

样本个数为 N ,属性个数为 M 的多元时间序列表示为 $X=\{X_1, X_2, \dots, X_i, \dots, X_N\}$,其中, $i \in \{1, 2, \dots, N\}$ 。多元时间序列 X 的每个数据样本代表每个时间点的值,表示为 $X_i=[x_{i,1}, x_{i,2}, \dots, x_{i,j}, \dots, x_{i,M}]$,其中, $j \in \{1, 2, \dots, M\}$, j 表示第 j 个属性, X_i 表示第 i 个时间点的样本数据, $x_{i,j}$ 表示第 i 个时间点第 j 个属性的值。

多元时间序列相空间重构就是在原序列 X 的基础上,对每个属性嵌入恰当的嵌入维数 m 和延迟时间 τ 。重构后的时间序列 X' 表示为 $X'=\{X'_1, X'_2, \dots, X'_i, \dots, X'_N\}$,其中, X'_i 表示 X_i 重构后的序列,即:

$$X'_i = [x_{i,1}, x_{i-\tau_1,1}, \dots, x_{i-(m_1-1)\tau_1,1}, \dots, x_{i,2}, x_{i-\tau_2,2}, \dots, x_{i-(m_2-1)\tau_2,2}, \dots, x_{i,j}, x_{i-\tau_j,j}, \dots, x_{i-(m_j-1)\tau_j,j}, \dots, x_{i,M}, x_{i-\tau_M,M}, \dots, x_{i-(m_M-1)\tau_M,M}],$$

其中, m_j 表示第 j 个属性的嵌入维数, τ_j 表示第 j 个属性的延迟时间。

当选择的嵌入维数和延迟时间恰当时, X_i 满足非线性关系,即:多元时间序列存在关系方程 f ,使得 $X'_{i+1} = f(X'_i)$ 。多元时间序列 X 通过相空间重构,包含序列随时间变化的动态信息,时间序列上的数据点之间形成相对稳定的关系,每个时间点代表动态关系系统中的一个分量,因此, X' 就可以近似地代表原时间序列的非线性动力系统。为多元时间序列相空间重构确定合适的 m 和 τ ,一直是复杂系统研究的重点,主要分为嵌入维数和延迟时间综合考虑法以及分别考虑两个参数的方法,如交互信息法、平均位移法、C-C 算法等。

1.1.1 平均位移法

平均位移法^[22]是同时考虑嵌入维数和延迟时间的相空间重构方法,思想是:通过引入平均位移(AD),给每个属性一个假设嵌入维数 m ,求延迟时间 τ 平均位移的求解公式为

$$\langle S_m(\tau_j) \rangle = \frac{1}{N} \sum_{t=1}^N \sqrt{\sum_{i=0}^{m-1} (x_{t-i\tau_j, j} - \bar{x}_{t, j})^2} \quad (1)$$

即:随机给某一属性赋值嵌入维数 m ,求对应的 $\langle S_m(\tau_j) \rangle$.原始的平均位移法原则是:当 $\langle S_m(\tau_j) \rangle$ 的增长斜率第 1 次降为初始值的 40%时,对应的点为所求的延迟时间.本文采用前人改进的平均位移法^[23],即:随着 τ_j 值增加, $\langle S_m(\tau_j) \rangle$ 的第 1 个峰值点对应的 τ_j 就是所求的延迟时间.

1.2 LM 算法

列文伯格-马夸尔特法(Levenberg-Marquardt,简称 LM)^[24]是一种使用广泛的最优化方法,是牛顿法(Newton's method)和梯度下降法(gradiant descent)的折中,通过迭代调整未知变量,求解二阶函数 $f(W)$ 的最优值,具有收敛速度快的优点.

令 W 为 L 个变量组成的向量, $W=[w_1, w_2, \dots, w_i, \dots, w_L]$.求解最优值的过程中,作用于向量 W 的最优调整量 ΔW 的计算公式为 $\Delta W=(H+\lambda I)^{-1}g$,其中, H 为多元函数 $f(W)$ 二阶偏导构成的 Hessian 矩阵,可以表示为

$$H = \begin{bmatrix} \frac{\partial^2 f}{\partial w_1^2} & \cdots & \frac{\partial^2 f}{\partial w_1 \partial w_L} \\ \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial w_L \partial w_1} & \cdots & \frac{\partial^2 f}{\partial w_L^2} \end{bmatrix} \quad (2)$$

I 为与 H 同维的单位矩阵, λ 为正则系数, g 为函数的梯度向量.为了化简由 Hessian 矩阵计算带来的复杂性,采用近似二阶偏导,忽略二阶以上的导数项代替二阶偏导^[25].假设二阶函数 $f(W)$ 的优化由如下代价函数产生:

$$f(W) = \frac{1}{2N} \sum_{t=1}^N [d_t - g(X_t, W)]^2 \quad (3)$$

d_t 表示真实值, $g(X_t, W)$ 是 d_t 的逼近函数,那么 $f(W)$ 的近似二阶偏导数项可以表示为

$$\frac{\partial^2 f}{\partial w_i \partial w_j} \approx \sum_{t=1}^N \left(\frac{\partial g(X_t, W)}{\partial w_i} \cdot \frac{\partial g(X_t, W)}{\partial w_j} \right) \quad (4)$$

其中, $i \in \{1, 2, \dots, L\}$, $j \in \{1, 2, \dots, L\}$, N 是训练样本个数.在迭代训练的过程中,除了每次计算权值调整量 ΔW 以外,也为正则系数 λ 分配足够大的值,保证 $H+\lambda I$ 正定,尽快收敛到最优解^[25].

1.3 RBF 神经网络

RBF 神经网络由 Moody 和 Darken 根据人体大脑皮层的感知区域特点提出的一种前馈型神经网络,网络结构如图 1 所示,通常包括输入层、隐含层和输出层^[26].其中,第 1 层输入层由感知神经元组成,将输入向量 X 引入神经网络,其中, $X=[X_1, X_2, \dots, X_i, \dots, X_n]$, n 表示输入层神经元个数;第 2 层隐含层把输入向量从低维映射到高维,实现高维曲线拟合,通常隐含层激励函数选择径向基函数 $\phi(X)$;最后一层是输出层,将隐含层的输出进行线性加权组合作为最终输出值,记为 Y .

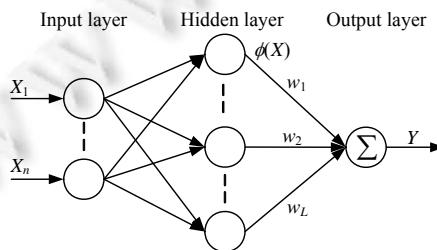


Fig.1 Topology structure chart of RBF neural networks

图 1 RBF 神经网络拓扑结构图

当输入样本为 n 时,输入层节点数为 $n(n \leq N^*)$,隐层节点个数为 L ,采用单输出,即输出层节点个数为 1.

2 一种基于多元时间序列的 Web Service QoS 预测方法

本文从多元时间序列的角度分析 QoS 数据,提出一种动态 Web 服务 QoS 预测方法 MulA-LMRBF,着重于多属性的数据分析和神经网络模型的改进,流程描述如图 2 所示。

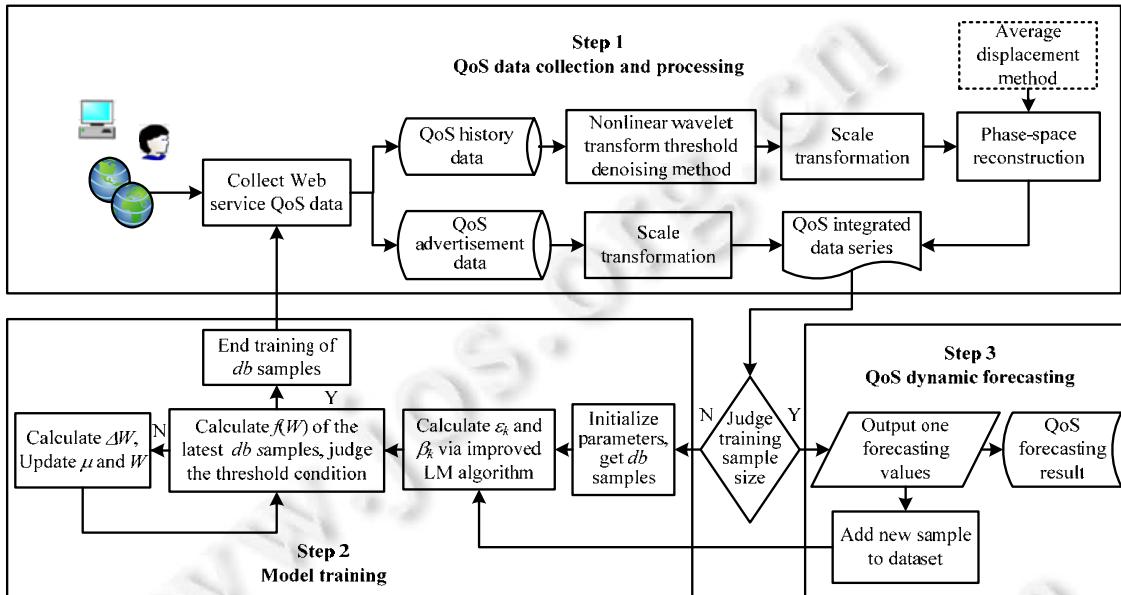


Fig.2 Mul-LMRBF architecture overview

图 2 Mul-LMRBF 总体结构图

用户或企业需要长期使用的 Web 服务可能由于动态的 Internet 网络变化产生短期或周期性的 QoS 变化,甚至发生服务故障,需要从长远角度预测服务的 QoS,为用户选择 Web 服务提供真实可靠的服务质量数据。MulA-LMRBF 方法充分利用 QoS 属性的历史数据信息并动态预测未来属性的具体值,主要概括为 3 个步骤。

- **QoS data collection and processing:** 确定 QoS 属性个数,选择 QoS 属性完备的样本作为实验数据。收集的数据包括历史数据和短期广告数据,分别对两部分数据进行预处理,历史数据处理包括数据噪声处理、尺度变换和相空间重构,广告数据仅尺度变换,从而形成综合的 QoS 数据序列;
- **Model training:** 设定隐层节点个数等初始化参数,通过最优化训练样本的误差函数 $f(W)$,采用改进方法训练神经网络隐含层和输出层间的权值 W ,进一步优化 W 的更新计算过程,达到高效训练的效果;
- **QoS dynamic forecasting:** 当训练样本满足误差函数 $f(W)$ 的阈值要求时训练结束,获取下一条新样本,对其预处理并保存预测结果,计算其 ϵ_k 和 β_k ,调整一次权值 W 。

2.1 数据收集和预处理

数据主要来自公开数据集和自测数据^[16,27],分别对历史数据和广告数据两部分进行预处理,具体由以下步骤组成。

(1) 历史数据(QoS history data)噪声处理

QoS 历史数据含有大量噪声,噪声会随时间演化和后续计算造成精度损失,并且相空间重构时间序列模型对数据噪声很敏感,含噪声数据会严重影响预测准确度,因此采用非线性小波变换阈值去噪法(nolinear wavelet transform threshold denoising approach)^[28-30]处理 QoS 历史数据。

(2) 数据尺度变换(scale transformation)

神经网络输入变量在[0,1]或[-1,1]时,网络运算效果较好^[19],因此对数据进行尺度变换处理,将 QoS 属性历

史数据和 QoS 广告数据都控制在[0,1]之间.尺度变换公式为

$$x_{i,j} = \frac{x_{i,j} - (x_{i,j})_{\min}}{(x_{i,j})_{\max} - (x_{i,j})_{\min}} \quad (5)$$

其中, $i \in \{1, 2, \dots, N\}$, $j \in \{1, 2, \dots, M\}$, $x_{i,j}$ 是 QoS 第 j 个属性的所有值, $(x_{i,j})_{\max}$ 是 $x_{i,j}$ 的最大值, $(x_{i,j})_{\min}$ 是 $x_{i,j}$ 的最小值.

(3) 历史数据相空间重构模型(phase-space reconstruction)

QoS 历史数据相空间重构,首先采用平均位移法确定重构的嵌入维数 m 和延迟时间 τ , m 从[1,30]取值,用公式(1)计算每个 QoS 属性的 m 对应的 $\langle S_m(\tau_j) \rangle$,取 $\langle S_m(\tau_j) \rangle$ 到达第 1 个峰值对应的 τ .然后均衡多个属性的 m 对应的 τ 值,选择所有属性的 m 对应 τ 达到平稳状态区间之内的值作为相空间重构的嵌入维数和延迟时间.

QoS 历史数据多元时间序列表示为 $Q = \{Q_1, Q_2, \dots, Q_i, \dots, Q_N\}$,其中,第 i 个数据 $Q_i = [q_{i,1}, q_{i,2}, \dots, q_{i,j}, \dots, q_{i,M}]$,第 j 个属性的嵌入维数为 m_j 和延迟时间为 τ_j .重构后的时间序列表示为 $Q'_i = [Q'_1, Q'_2, \dots, Q'_i, \dots, Q'_N]$,其中,第 i 个数据 Q'_i 表示 Q_i 重构后的时间序列,表示为

$$Q'_i = [q_{i,1}, q_{i-\tau_1,1}, q_{i-2\tau_1,1}, \dots, q_{i-(m_1-1)\tau_1,1}, q_{i,2}, q_{i-\tau_2,2}, q_{i-2\tau_2,2}, \dots, q_{i-(m_2-1)\tau_2,2}, \dots, q_{i,j}, q_{i-\tau_j,j}, q_{i-2\tau_j,j}, \dots, q_{i-(m_j-1)\tau_j,j}, \dots, q_{i,M}, q_{i-\tau_M,M}, q_{i-2\tau_M,M}, \dots, q_{i-(m_M-1)\tau_M,M}] \quad (6)$$

其中, $i \in \{1, 2, \dots, N\}$,相空间重构时选择的数据样本个数为 N ,属性个数为 M ,分别为每个属性计算合适的 m 和 τ .例如,假设某一 Web 服务的响应时间(response time,简称 RT)的嵌入维数为 2,延迟时间为 1,可靠性(reliability,简称 R)的嵌入维数为 2,延迟时间为 2,在 t 时刻去噪和尺度变换后的数据 Q_t 为 $Q_t = [RT_t, R_t]$, Q_t 相空间重构后为 $Q'_t = [RT_t, RT_{t-1}, RT_{t-2}, R_t, R_{t-2}, R_{t-4}]$.重构后的 Q'_t 充分利用历史数据样本,近似恢复 RT 和 R 属性共同的原数据关系系统,比原数据 Q_t 包含更多 QoS 属性的动态信息,因此我们将相空间重构后的历史数据用于 QoS 的动态多步预测.

(4) QoS 综合数据序列(QoS integrated data serirs)

处理后的 QoS 历史数据和 QoS 广告数据时间序列组成 QoS 综合数据序列 X ,表示为 $X = \{X_1, X_2, \dots, X_i, \dots, X_N\}$,预测值序列为 $Y = \{Y_{1+\eta}, Y_{2+\eta}, \dots, Y_{i+\eta}, \dots, Y_{N+\eta}\}$.其中,第 i 个输入样本 $X_i = [Q'_i, A'_i]^T$,广告序列 $A_i = [a_{i,1}, a_{i,2}, \dots, a_{i,j}, \dots, a_{i,M}]$,处理后的广告序列 $A'_i = [a'_{i,1}, a'_{i,2}, \dots, a'_{i,j}, \dots, a'_{i,M}]$, Q'_i 表示处理后的历史数据序列, $i \in \{1, 2, \dots, N\}$, $j \in \{1, 2, \dots, M\}$, N 为样本个数, M 为 QoS 属性个数, η 为预测步长.继续上例,假设第 t 个样本对应步长为 η 时刻的广告序列为 $A_t = [ART_{t+\eta}, AR_{t+\eta}]$,处理后为 $A'_t = [ART'_{t+\eta}, AR'_{t+\eta}]$,因此, t 时刻的综合数据表示为:

$$X_t = [RT_t, RT_{t-1}, RT_{t-2}, R_t, R_{t-2}, R_{t-4}, ART'_{t+\eta}, AR'_{t+\eta}] .$$

2.2 LM 算法改进的RBF神经网络预测模型

LM 算法改进的 RBF 神经网络主要利用 LM 算法的最优化思想,训练网络隐含层与输出层权值 W .QoS 综合数据序列的数据作为输入,隐含层节点个数固定不变,输出层节点个数为 1,因此隐含层与输出层权值最优时,网络的实际输出值与真实值最接近.我们利用 LMRBF 网络的优点并进一步改进,实现高效训练和动态预测的目标,提高预测精度.

RBF 神经网络模型^[31]的输入为 X_i ,输出为 Y_i ,隐含层激励函数选择高斯函数,其公式为

$$\phi(X_i, C_k) = \exp\left(-\frac{\|X_i - C_k\|^2}{2\sigma_k^2}\right) \quad (7)$$

其中, $i \in \{1, 2, \dots, N\}$, N 表示样本个数, $k \in \{1, 2, \dots, L\}$, L 表示隐含层节点数, $\phi(r)$ 为隐含层激励函数; C_k 为 RBF 神经网络隐含层中心, σ_k 为第 k 个隐层节点的扩展常数,其求解公式为

$$\sigma_k = \lambda d_k \quad (8)$$

$$d_k = \min(\|c_k - c_t\|), k \neq t \quad (9)$$

d_k 是第 k 个隐层节点与其他隐层节点的最小距离, k 和 $t \in \{1, 2, \dots, L\}$, $t \in \{1, 2, \dots, L\}$, λ 是重叠系数, σ_k 是第 k 个隐层节点的扩展常数.RBF 神经网络输出层公式为

$$Y_i = \sum_{k=1}^L w_k \phi(X_i, C_k) = \sum_{k=1}^L w_k \exp\left(-\frac{\|X_i - C_k\|^2}{2\sigma_k^2}\right) \quad (10)$$

其中, $i \in \{1, 2, \dots, N\}$, W 是隐含层与输出层的权值向量, $W = [w_1, w_2, \dots, w_L]^T$, Y_i 为输出层函数, w_k 为第 k 个隐层节点与输出节点之间的权值.

(1) 模型训练阶段(model training)

模型训练的目的是满足误差函数 $f(W)$ 尽可能小, 直到预测精度满足阈值条件. 当不满足阈值条件时, 迭代更新 W 的值, 使得 $f(W)$ 达到阈值 δ 的要求. 即 $f(W) > \delta$ 时, 更新权值 W . 误差函数 $f(W)$ 的计算公式为

$$f(W) = \frac{1}{2N} \sum_{i=1}^N s_i^2 = \frac{1}{2N} \sum_{i=1}^N (Y_i - T_i)^2 \quad (11)$$

其中, T_i 表示样本真实值, Y_i 表示 RBF 神经网络的实际输出值, s_i 表示第 i 个样本的预测误差, 则 N 个训练样本的预测值与真实值的误差矩阵 $S = [s_1, s_2, \dots, s_i, \dots, s_N]$.

利用 LM 算法训练 RBF 权值 W 的过程, 见算法 1, 训练样本训练时, W 迭代更新的公式为

$$W = W + \Delta W \quad (12)$$

$$\Delta W = (J^T J + \mu I)^{-1} J^T S \quad (13)$$

即: 通过每次迭代调整神经网络权值, 使网络输出值最大程度接近数据真实值. 公式(13)中, 权值 W 的调整量 ΔW 利用近似二阶导数 $J^T J$ 代替原来复杂的 Hessian 矩阵计算, $f(W)$ 的 Jacobian 矩阵 J 为

$$J = \begin{bmatrix} \frac{\partial(s_1)}{\partial w_1} & \frac{\partial(s_1)}{\partial w_2} & \dots & \frac{\partial(s_1)}{\partial w_L} \\ \frac{\partial(s_2)}{\partial w_1} & \frac{\partial(s_2)}{\partial w_2} & \dots & \frac{\partial(s_2)}{\partial w_L} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial(s_N)}{\partial w_1} & \frac{\partial(s_N)}{\partial w_2} & \dots & \frac{\partial(s_N)}{\partial w_L} \end{bmatrix} \quad (14)$$

正则化系数 μ 的取值在 LM 算法优化未知参量的过程中起决定性的作用, 第 n 次迭代训练, 如果 $f(W)$ 值大于第 $n-1$ 次迭代 $f(W)$ 的值, 参数值 $\mu = \mu \times a$ ($\mu > 0, a > 1$); 否则 $\mu = \mu/a$, 并更新权值 W .

虽然采用 LM 算法改进 RBF 神经网络训练权值可以快速地收敛到最优解, 分析迭代更新公式(12)~公式(14)可知: 计算权值调整量 ΔW 需要耗费复杂的开销, 矩阵 J 需要存储所有训练样本的神经网络输出函数, 进而才能计算 $J^T J$ 和 $J^T S$, 因此, 优化网络训练的主要工作集中到 Jacobian 矩阵的存储以及与它相关的矩阵计算. Wang 等人采用 LM 算法改进 ELM 神经网络^[18], 通过公式改进, 进一步优化了预测模型. 本文启发性地从 Jacobian 矩阵和相关矩阵计算等方面优化 MulA-LMRBF 动态预测模型:

矩阵 J 是由全部训练样本输出函数相关的偏导项构成的, 因此需要所有训练样本经过一次模型计算才可以进行权值调整. 我们将预处理后的 N 个训练样本分为 db (data block, $db \geq 1$) 长度的若干段, 当样本量达到 db 时, 计算一次误差函数 $f(W)$ 的值并判断 $f(W)$ 的阈值条件: 满足条件, 则代表本段样本训练结束; 否则继续迭代, 直到 $f(W) \leq \delta$. 训练阶段重复执行上述步骤, 每次判断新 db 个样本的 $f(W)$ 是否满足阈值条件, 直到全部训练样本训练结束.

权值调整量过程中, 计算 $J^T J$ 的时间复杂度为 $O(n^3)$, $J^T S$ 的时间复杂度为 $O(n^2)$, 空间复杂度为 $O(n^2)$. 进一步简化计算, Jacobian 矩阵中的偏导项 $\partial(s_i)/\partial w_j$ 进一步化简为

$$\frac{\partial(s_i)}{\partial w_j} = \frac{\partial(Y_i - T_i)}{\partial w_j} = \frac{\partial \left(\sum_{k=1}^L w_k \phi(X_i, C_k) \right)}{\partial w_j} = \frac{\partial(w_j \phi(X_i, C_j))}{\partial w_j} = \phi(X_i, C_j) \quad (15)$$

因此, 矩阵 J 可以化简为 Γ 的形式:

$$J = \begin{bmatrix} \phi(X_1, C_1) & \phi(X_1, C_2) & \dots & \phi(X_1, C_L) \\ \phi(X_2, C_1) & \phi(X_2, C_2) & \dots & \phi(X_2, C_L) \\ \vdots & \vdots & \ddots & \vdots \\ \phi(X_N, C_1) & \phi(X_N, C_2) & \dots & \phi(X_N, C_L) \end{bmatrix} = \Gamma \quad (16)$$

可以看出, Γ 是由神经网络隐含层的输出函数构成, 每行代表一条样本经过网络模型的隐含层输出.

采用化简矩阵 Γ 计算权值调整量 ΔW , 根据 Γ 矩阵的特点, 依次化简 $J^T J$ 和 $J^T S$ 的计算.

a) 首先优化计算 $J^T J$, 可以用如下公式表示:

$$J^T J = \Gamma^T \Gamma = \sum_{k=1}^N \varepsilon_k^T \varepsilon_k \quad (17)$$

$$\varepsilon_k = [\phi(X_k, C_1), \phi(X_k, C_2), \dots, \phi(X_k, C_L)] \quad (18)$$

b) 然后类比上述优化 $J^T S$ 的计算:

$$J^T S = \Gamma^T S = \sum_{k=1}^N \varepsilon_k^T s_k \quad (19)$$

$$\beta_k = s_k [\phi(X_k, C_1), \phi(X_k, C_2), \dots, \phi(X_k, C_L)]^T \quad (20)$$

其中, ε_k 是第 k 个样本对应的隐含层输出向量, s_k 表示第 k 个样本的预测误差.

根据步骤 a)、步骤 b) 总结, W 训练过程无需等到所有训练样本经过模型输出, 进行复杂的矩阵计算, $J^T J$ 和 $J^T S$ 的时间复杂度分别降为 $O(n^2)$ 和 $O(n)$. 每当一个样本经过预测模型, 就保存其隐含层输出和预测误差, 并计算 $\varepsilon_k^T \varepsilon_k$ 和 β_k , 累加计算便得到 $J^T J$ 和 $J^T S$, 每次只需存储一个样本的 ε_k 和 β_k , 空间复杂度降为 $O(n)$, 经过参数调整, 最后更新权值 W . 整体算法的简要描述见算法 1.

算法 1. LM 算法改进的 RBF 神经网络.

初始化: $f(W)=0, \varepsilon_k=0, \beta_k=0; db, L, \mu$, 向量 W, S 随机赋值;

输出: 更新后的权值 W .

1. $f(W_1)=f(W); // f(W_1)$ is $f(W)$ in the last iteration
2. Calculate ε_k and β_k ;
3. **When** $count=db$ **do**
4. Calculate $f(W)$, W ;
5. **while** $f(W)>\delta$ **do**
6. $f(W_2)=f(W); // f(W_2)$ is $f(W)$ in the this iteration
7. Calculate ΔW ;
8. **if** $f(W_2)>f(W_1)$
9. $\mu=a*\mu; // \mu$ is the regularization coefficient
10. **else**
11. $\mu=\mu/a$;
12. Update W , $W=W+\Delta W$;
13. Calculate $f(W)$;
14. **end while**

(2) 动态预测(QoS dynamic forecasting)

本文采用 LM 算法改进 RBF 神经网络训练权值 W , 在时间复杂度、权值调整量计算等方面有明显改进. 模型动态预测阶段, 延续训练阶段采用改进算法训练权值的思想, 输入新数据动态更新权值 W . 每次权值调整过程中, 正则化系数 μ 不断调整的作用在于: 当 μ 趋近于 0 时, 方法近似于训练速度快的高斯牛顿法, 权值调整量 ΔW 调整地缓慢; 当 μ 取值很大时, 方法近似于梯度下降法, ΔW 调整幅度大, 每迭代成功一步, μ 值减小并逐步回归到高斯牛顿法.

为了使模型动态长期地预测 QoS 属性值, 训练样本达到数量要求, 训练结束后, 当采集到一条在线数据时, 首先进行 Step 1 的步骤处理, 形成 QoS 综合数据序列; 经过 Step 3 调整模型输出值作为预测结果; 为实现模型参数更新, 将新数据组成样本对, 转向 Step 2, 计算该样本的 ε_k 和 β_k , 计算最新的 db 个样本的误差函数 $f(W)$, 判断阈值条件, 当不满足时, 根据误差函数 $f(W)$ 的增减情况调整参数 μ 以及权值 W . 随着在线数据的实时采集, 模型参数不

断更新,适应动态、非线性的 QoS 预测要求,从而提高了预测的准确性.

3 实验

3.1 实验设置

本文实验数据主要有 5 个部分:第 1 部分(Sourceforge)(<https://sourceforge.net/projects/qosmonitoring/files/>)、第 2 部分(<http://www.datatang.com/data/15932>)和第 3 部分数据(<http://www.datatang.com/data/15938>)来源于开源数据集,第 4 部分是笔者采用公开方法(<https://www.ibm.com/developerworks/library/ws-quality/>)收集的数据,第五部分是短期 QoS 广告数据.上述数据集,除第 3 部分采用响应时间(response time,简称 RT)、吞吐量(throughput,简称 T)、可靠性(reliability,简称 R)和可用性(availability,简称 A)这 4 个属性,其他数据集主要包含响应时间和吞吐量这两个 QoS 属性,利用多属性数据预测未来响应时间.实验环境为 Intel(R) Core(TM) i5-4200U CPU@1.60GHz,4.00GB RAM,Windows 7,matlab 7.11.

其中第 1 部分数据的采集时间是每天 8:00~17:00,连续每 15 分钟记录一次 Web 服务的响应时间和吞吐量,共 4 个 Web 服务,取每个 Web 的连续 2 000 条数据实验.以其中一个服务 RMB Instant Quotation 为例分析实验过程和结果,如图 3(a)所示,为 RMB 数据的曲线图.第 2 部分主要来自 142 台分布式计算机的 4 532 个真实 Web 服务的 QoS 数据,选择部分 Web 服务的数据实验.第 3 部分是来自 150 台分布式计算机,100 个 Web 服务的监控采集结果,除响应时间和数据量等信息外,还包括服务的 HTTP 信息,反映服务当前可用情况,本实验根据 HTTP 信息、访问服务失败次数和服务失效时间,模拟 QoS 可靠性和可用性.第 4 部分为作者采集的数据,选择多个的 Web 服务 ID,每个服务采集时间间隔为 10 分钟,每个 ID 记录了 2 000 多个样本,选择 MobileCode 为例进行实验,原数据如图 3(b)所示.由于本文选择的 Web 服务 QoS 属性数据大部分都是早期采集的,未提供广告数据,所以第五部分数据主要通过模拟生成 QoS 的响应时间广告数据,根据 QoS 属性呈现非线性、动态的特点以及 Web 服务呈现的间断性优化的趋势,在原数据的曲线图上,以一天为周期添加若干趋势线,与真实数据的拟合度控制在 50%~70%.

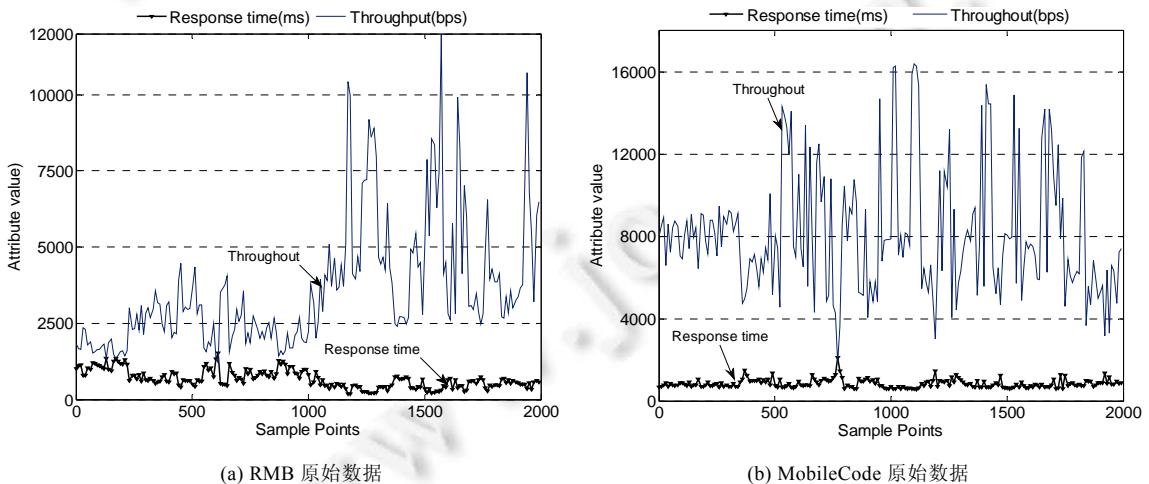


Fig.3 RMB original data and MobileCode original data

图 3 RMB 原始数据和 MobileCode 原始数据

实验通过均方根误差(the root mean square error,简称 RMSE)分析实验,更直观地比较不同方法的预测结果:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - T_i)^2} \quad (21)$$

其中, Y_i 为第 i 个预测值, T_i 为第 i 个真实值, N 为样本数量.RMSE 表示预测相对误差的大小,反映预测的稳定性.

3.2 实验过程

希望通过实验证明使用相空间方法构建属性关系、采用广告数据提高了多步预测的准确度,验证 QoS 多元时间序列适合多步、中长期动态预测,通过对比实验阐明该预测模型的准确性。

从数据集中选择若干 Web 数据实验后,本文分别介绍基于单元时间序列 LMRBF 预测方法(S-LMRBF)、基于多元时间序列相空间重构的 LMRBF 预测方法(Mul-LMRBF)、基于多元时间序列相空间重构和带广告数据的 LMRBF 预测方法(MulA-LMRBF)这 3 组实验,通过对比观察相空间重构和广告数据对多元多步预测的影响,验证多元时间序列在多步、中长期动态预测时,比单元时间序列预测精度高。与传统静态 RBF 神经网络预测方法^[26,31]和 ARMA 预测方法^[32]比较,证明本方法在精确度、动态多步预测方面的优势。简单步骤描述如下。

- (1) 将 QoS 历史数据的多元时间序列进行处理,减少噪声并变换数据尺度,数据处理后扰动性减小。如图 4 所示,为 RMB 和 MobileCode 处理后的结果;
- (2) 对预处理数据进行相空间重构,利用平均位移法同时考虑 m 和 τ ,计算 m 在 [1,40] 范围内的每个 m 对应的 τ ,如图 5(a) 和图 5(b) 所示:随着 m 的增加,重构相空间满足的 τ 整体呈减小趋势。如图 5(a),RMB 数据的 m 为 [1,3] 时, τ 的波动较大,重构的相空间处于不稳定状态;当 $m > 10$ 时,一方面相空间重构耗费样本量过多,约耗费 40%~50% 的样本,另一方面,不同属性的 m - τ 图的值不稳定,因此 RMB 数据从 [4,8] 范围内选择嵌入维数。
- (3) 选择步长 η ($\eta \geq 1$),则样本表示为 $\{X_i, T_{i+\eta}\}, i \in \{1, 2, \dots, N\}$,建立预测模型进行模型训练,当达到训练样本数量时,动态预测未来属性值。当数据采集及时的情况下,本方法支持 Web 服务 QoS 动态在线预测,若数据采集频度很低或出现大比例缺失数据,动态预测无法正常进行。另外,本方法现在仅限于一定阈值范围内的多步预测,当 η 超过范围时,不能达到预测精度要求;同时,当 η 很短时,数据进行相空间重构的优势不明显。因此,实验总结平均最佳多元时间序列预测步长的适用范围为 [2,8]。

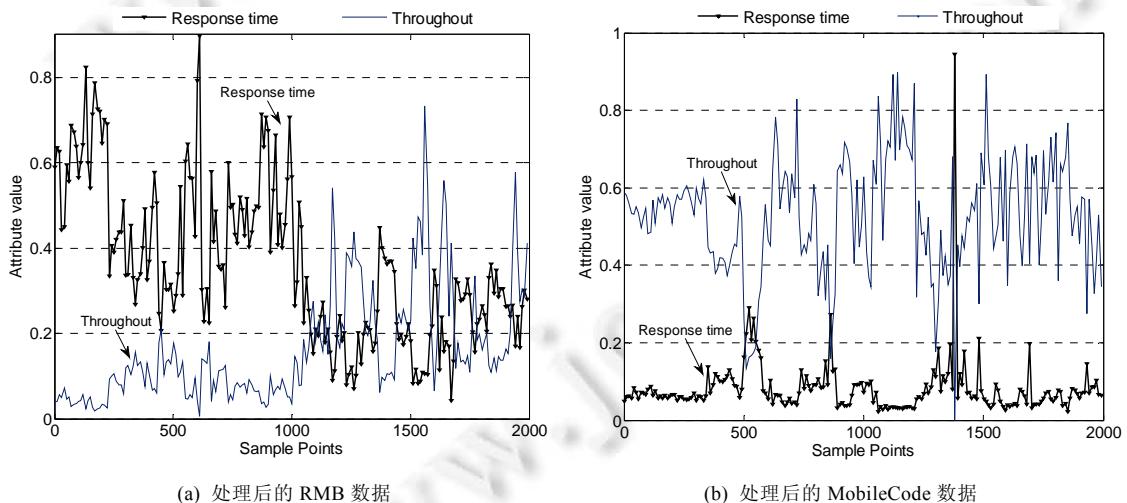
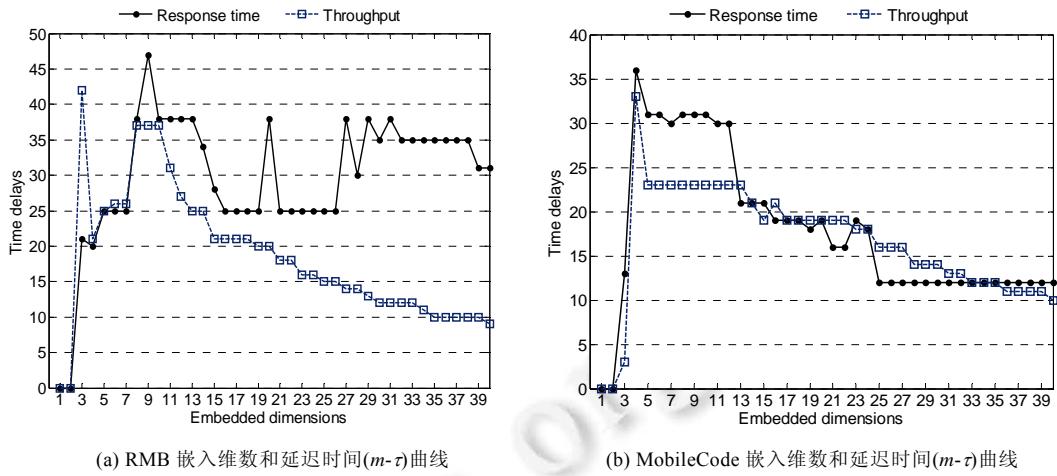


Fig.4 Processed RMB data and processed MobileCode data

图 4 处理后的 RMB 数据和处理后的 MobileCode 数据

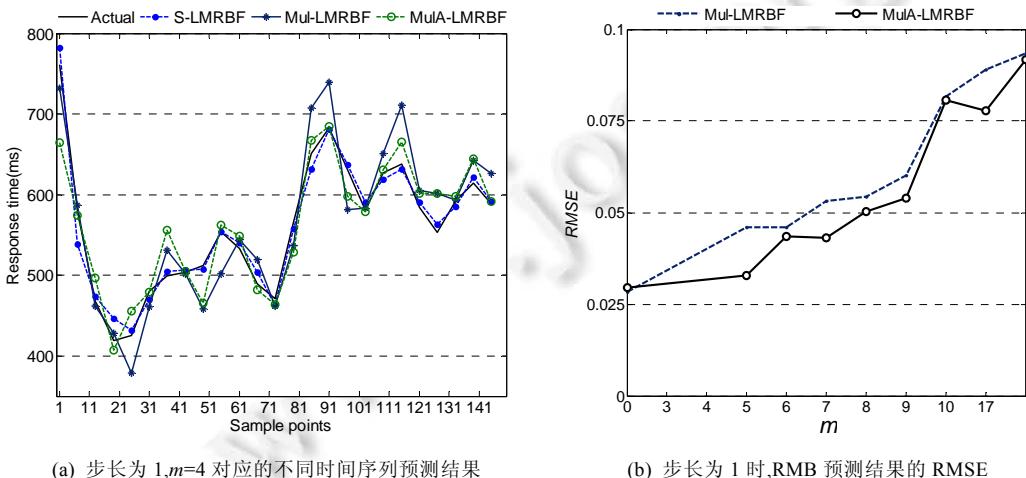
Fig.5 $m-\tau$ curve for RMB data and $m-\tau$ curve for MobileCode data图 5 RMB 以及 MobileCode 嵌入维数和延迟时间($m-\tau$)曲线

3.3 实验结果分析

3.3.1 相空间重构和广告数据对预测影响

为证明相空间重构对动态多步预测的影响以及广告数据对预测精度的影响,通过若干组实验分析验证。以RBM数据为例,取1 000组训练样本,300个测试样本, m 在[3,8]范围取值,分别做单步和多步预测实验。如图6所示,截取不同相空间重构下单步预测结果和RMSE的对比,实验的RMSE采用归一化数据计算。

图6(a)为单步预测结果,可以看出S-LMRBF预测结果拟合度较高,说明QoS单元时间序列的信息可以实现单步预测。图6(b)为单步预测的RMSE, m 在[3,17]范围内的取值分别代表不同 m 对应的相空间重构情况。从图中可以看出:单步预测时,Mul-LMRBF的误差值略大于S-LMRBF,MulA-LMRBF比Mul-LMRBF的预测误差值小,大于S-LMRBF预测误差。说明当预测步长较短时,相空间重构和广告数据对预测准确性影响不大。

Fig.6 Forecasting results when $step=1$, $m=4$ and RMSE when $step=1$ 图 6 步长为 1, $m=4$ 对应的不同时间序列预测结果和步长为 1 时,RMB 预测结果的 RMSE

如图7所示为不同相空间重构条件下,多步预测的对比实验结果。 $m=4,6,8$ 分别进行步长为 3 和 5 的预测,从 6 个对比结果中看出:步长增加,预测误差都会增加,但多元 MulA-LMRBF 和 Mul-LMRBF 预测结果比单元

S-LMRBF 预测结果的拟合好,取不同相空间重构参数值,预测结果也不同,当重构维数 m 取值在 $m-\tau$ 曲线稳定的范围内时,预测结果具有较高拟合度。因此,相空间重构参数要综合考虑 m 和 τ 两个参数,取参数值共同稳定的范围。MulA-LMRBF 的拟合结果优于 Mul-LMRBF,广告数据进一步提高了预测精度,因此,采用服务提供商提供的相对真实可靠的广告数据进行 QoS 多步预测会进一步提高预测精度。

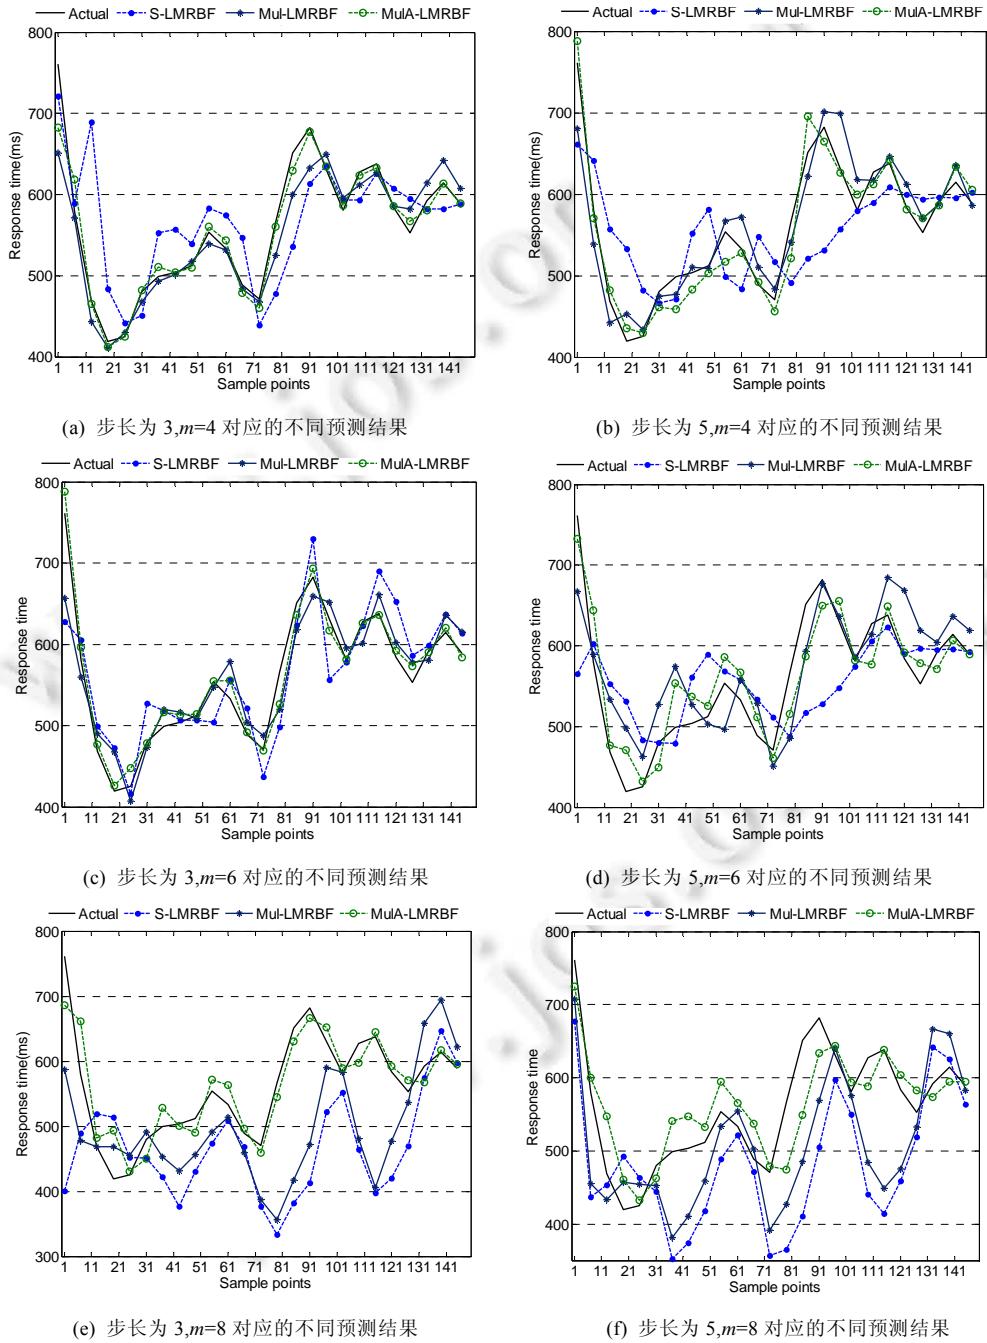


Fig.7 Forecasting results when different step and m

图 7 不同步长、不同 m 对应的不同预测结果

3.3.2 多元对预测步长的影响

通过相空间重构和广告数据的实验,充分证明恰当的相空间和广告数据能提高多步预测精度。以相空间重构 m 在[3,10]范围内的值为例,通过实验调整步长,观察随步长增加单元(S-LMRBF)、无广告多元(Mul-LMRBF)、带广告多元(MulA-LMRBF)这3种预测的均方根误差 RMSE 变化情况。从数据集中选择若干个完整的 Web 服务 QoS 数据分别进行对比实验,实验证明:多步预测时,MulA-LMRBF 的 RMSE 值最小,Mul-LMRBF 和 MulA-LMRBF 多步预测的 RMSE 普遍优于 S-LMRBF 单元预测结果。

图 8 是 RMB 数据 300 个测试样本的多步预测 RMSE 示例。当 $Step < 3$ 时,S-LMRBF 的 RMSE 值明显低于 Mul-LMRBF 和 MulA-LMRBF 的值,说明小步长范围内,单元时间序列可实现较高精度预测。 $Step \geq 3$,所有预测的 MulA-LMRBF 明显优于其他预测的 RMSE,其中, $m=4$ 时,Mul-LMRBF 优于 S-LMRBF; $m=6$ 时, $Step$ 在[3,9]及大于 10 范围内 Mul-LMRBF 小于 S-LMRBF 的 RMSE。因此,加入广告的 MulA-LMRBF 一直比未加入广告数据 Mul-LMRBF 预测结果的 RMSE 小。

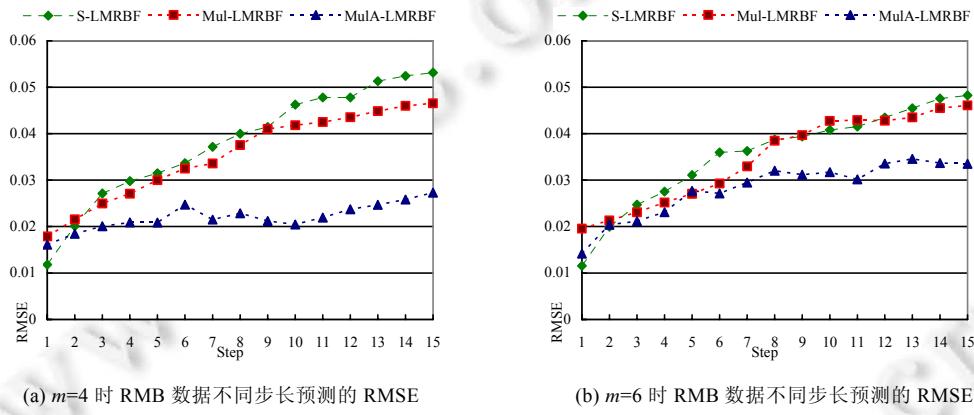


Fig.8 RMSE when $m=4$ for RMB data and RMSE when $m=6$ for RMB data

图 8 $m=4$ 时 RMB 数据不同步长预测的 RMSE 和 $m=6$ 时 RMB 数据不同步长预测的 RMSE

如图 9 所示是自己采集的 MobileCode 数据预测 RMSE 对比图,选择 $m-\tau$ 曲线平稳范围内的相空间重构参数。以 $m=5$ 为例,RMSE 随步长变大呈增长趋势,当步长大于 1 时,Mul-LMRBF 和 MulA-LMRBF 的预测 RMSE 总体上优于 S-LMRBF,多元 Mul-LMRBF 在[2,5]步长范围内小于单元 S-LMRBF 的 RMSE 值。

从第 2 组数据堂数据中选择 258 组 QoS 数据完整的 Web 服务进行实验,统计 m 在[3,10]范围内不同步长取值的 RMSE 值。如图 10 为 $m=4$ 时,258 组实验的平均 RMSE。

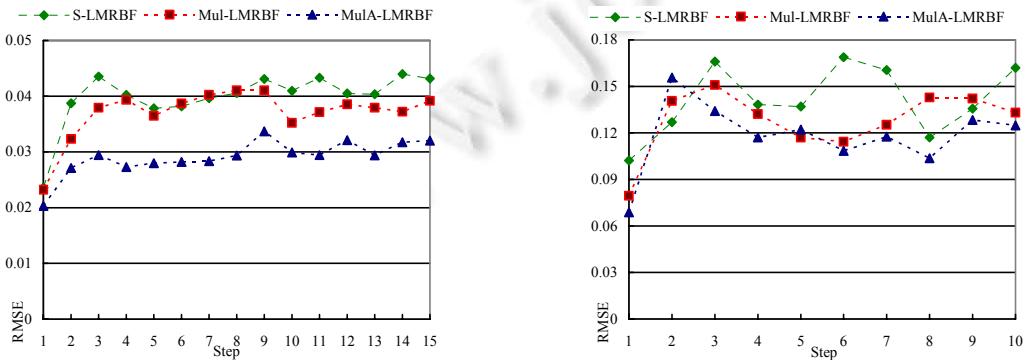


Fig.9 RMSE when $m=5$ for MobileCode data

图 9 $m=5$ 时 MobileCode 不同步长预测的 RMSE 图 10 $m=4$ 时 258 组 Web 服务的不同步长预测的平均 RMSE

Fig.10 Average RMSE for 258 Web Services data

如图 10 所示,当 Step 在[3,7]范围时,带广告的多元 MulA-LMRBF 预测误差明显优于 Mul-LMRBF 和 S-LMRBF,与 S-LMRBF 相比,MulA-LMRBF 的 RMSE 平均减小 19%,多元 Mul-LMRBF 比 S-LMRBF 平均降低了 16%.说明多元时间序列更适合多步长预测,可靠的广告数据会提高预测的准确度.根据实验统计,模型的平均最佳多步预测步长范围是[2,8].

3.3.3 对比实验

对比传统 RBF 神经网络模型、ARMA 模型和本文提出的 MulA-LMRBF 预测模型,步长分别取 1,3 和 5,分析预测值和实际值的拟合情况以及预测的均方根误差 RMSE.

以 RMB 数据集为例,首先用 S-LMRBF 单步预测结果对比传统 RBF 神经网络、ARMA 单元单步预测结果,如图 11(a);然后,用 $m=6$ 对应的 Mul-LMRBF 多步预测结果对比传统方法预测结果,如图 11(b),多步预测的 RBF 和 ARMA 都采用响应时间和吞吐量两属性的历史数据.S-LMRBF 和 MulA-LMRBF 分别对应不同步长预测值.

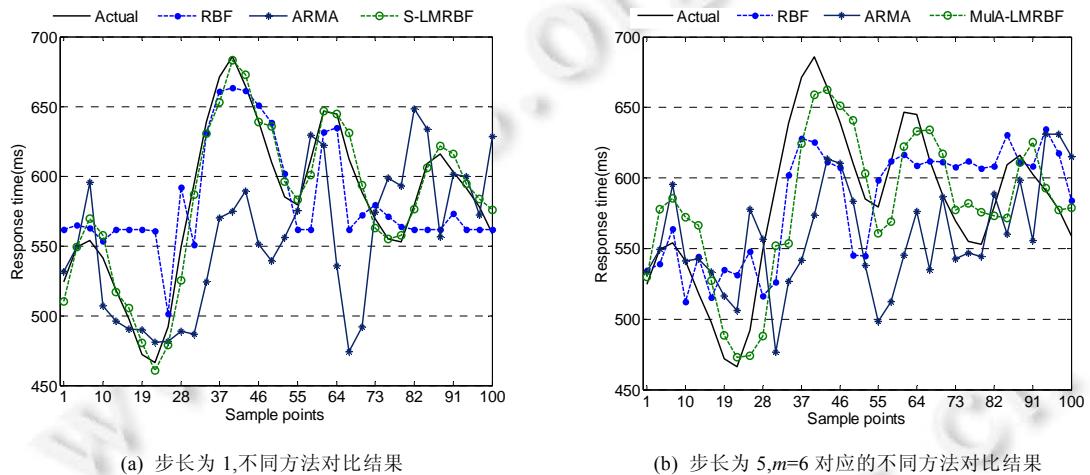


Fig.11 Comparison of forecast results for RMB, when $m=6$, $step=1$
and Comparison of forecast results for RMB, when $m=6$, $step=5$

图 11 步长为 1,不同方法对比结果和步长为 5, $m=6$ 对应的不同方法对比结果

表 1 为 RMB 数据预测结果的 RMSE,综合分析都优于 RBF 和 ARMA 的预测结果.表 2 为 MobileCode 数据 300 个样本点的对比实验 RMSE 统计值,步长分别取 1,3,5,多元取 $m=6$ 进行相空间重构.从表中可以看出:相比其他方法,MulA-LMRBF 和 S-LMRBF 的 RMSE 值都比较小,具有更好的预测精度.

Table 1 Comparison of RMSE for RMB data forecasting results

表 1 RMB 数据预测结果 RMSE 指标比较

| 服务 方法 | RMB instant quotation | | | |
|----------|-----------------------|---------|---------|------------|
| | RBF | ARMA | S-LMRBF | MulA-LMRBF |
| Step=1 | 0.082 7 | 0.119 3 | 0.011 5 | 0.014 2 |
| Step=3 | 0.095 5 | 0.147 3 | 0.024 7 | 0.021 1 |
| Step=5 | 0.115 9 | 0.206 2 | 0.031 1 | 0.027 6 |

Table 2 Comparison of RMSE for MobileCode data forecasting results

表 2 MobileCode 数据预测结果 RMSE 指标比较

| 服务 方法 | MobileCode | | | |
|----------|------------|---------|---------|------------|
| | RBF | ARMA | S-LMRBF | MulA-LMRBF |
| Step=1 | 0.100 4 | 0.143 1 | 0.023 6 | 0.020 3 |
| Step=3 | 0.159 2 | 0.194 2 | 0.043 5 | 0.029 4 |
| Step=5 | 0.127 4 | 0.225 1 | 0.037 8 | 0.028 0 |

为进一步验证方法的通用性,将方法应用在数据集 2 收集到的 258 个完整的包含响应时间(response time,简称 RT)和吞吐量(throughput,简称 T)的 Web 服务数据,表 3 为预测结果的平均 RMSE。通过对比实验,进一步证明了 MulA-LMRBF 和 S-LMRBF 的 RMSE 值最小,特别是在多步长预测时,MulA-LMRBF 要明显优于 S-LMRBF。因此进一步证明了本文提出的 MulA-LMRBF 预测精度优于传统的 RBF 和 ARMA 方法,并且在动态和多步预测时,具有更好的预测效果。

Table 3 Comparison of RMSE for 258 Web services data average forecasting results

表 3 第 2 组 Web 预测平均 RMSE 指标比较

| 服务 方法 | 258 组 Web 服务(平均) | | | |
|----------|------------------|---------|---------|------------|
| | RBF | ARMA | S-LMRBF | MulA-LMRBF |
| Step=1 | 0.120 8 | 0.159 7 | 0.102 1 | 0.068 8 |
| Step=3 | 0.173 5 | 0.160 5 | 0.165 9 | 0.136 9 |
| Step=5 | 0.205 9 | 0.217 2 | 0.136 9 | 0.122 0 |

表 4 为第 3 部分数据集中 $ClientIP=128.83.122.179$ 的平均 RMSE 结果,第 3 部分数据集采用 4 个 QoS 属性,比较平均 RMSE 可以看出当 Step=3 和 5 时,MulA-LMRBF 的预测结果明显优于单元时间序列 S-LMRBF。整体比较,本文改进算法 MulA-LMRBF 的预测 RMSE 比传统方法大约降低了 50%,比 S-LMRBF 降低了 20% 左右。

Table 4 Comparison of RMSE for the third data set average forecasting results

表 4 数据堂数据集的平均 RMSE 指标比较

| 服务 方法 | ClientIP=128.83.122.179(平均) | | | |
|----------|-----------------------------|---------|---------|------------|
| | RBF | ARMA | S-LMRBF | MulA-LMRBF |
| Step=1 | 0.087 0 | 0.085 5 | 0.018 9 | 0.017 5 |
| Step=3 | 0.102 1 | 0.100 2 | 0.022 8 | 0.019 2 |
| Step=5 | 0.119 6 | 0.118 3 | 0.031 6 | 0.023 3 |

4 结论与未来工作

现有的 Web 服务 QoS 预测方法存在预测周期短、动态能力差、属性之间相互影响考虑不足等问题,针对上述问题,本文提出了一种基于多元时间序列的 QoS 预测方法 MulA-LMRBF。首先,该方法考虑多个 QoS 属性之间的关系,采用相空间重构描述并恢复各个属性值在时间变化中存在的非线性、动态系统,刻画属性间存在的关联;然后,利用服务广告数据近似表示属性值的未来趋势,将历史数据和广告数据共同组成预测的综合数据序列,实现多步长周期预测;为了改善原 RBF 神经网络模型训练计算过程并实现动态预测,最后采用 LM 算法优化 RBF 神经网络模型,随着在线样本采集,模型参数更新。

在未来的工作中,将重点考虑以下几个问题。一是现有的计算相空间重构嵌入维数和延迟时间的方法并不完善,目前运用的平均位移法可以提高预测的准确性,但参数未证实最优,相空间重构一直存在很大的研究挑战,参数值的选择一直是研究热点,后期进一步研究综合考虑嵌入维数和延迟时间的方法;二是本方法只选择网络权值为动态参数,动态性还不够完备,隐层节点个数等方面未考虑。本文从时间序列数据分析和预测方面研究 QoS 预测,现实网络中,需要 Web 服务数据实时收集、数据分析和处理、动态预测模型等更完备的系统支持,今后可更全面地研究;三是目前只考虑响应时间和吞吐量两个 QoS 属性预测响应时间,后期会进一步改进模型,可同时预测多个 QoS 属性值。

References:

- [1] Ma Y, Wang SG, Sun QB, et al. Web service quality metric algorithm employing objective and subjective weight. *Ruan Jian Xue Bao/Journal of Software*, 2014,25(11):2473–2485 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/4508.htm> [doi: 10.13328/j.cnki.jos.004508]
- [2] Grunske L. Specification patterns for probabilistic quality properties. In: Proc. of the Int'l Conf. on Software Engineering. DBLP, 2008. 31–40.

- [3] Ma H, Zhu H, Hu Z, *et al.* Multi-valued collaborative QoS prediction for cloud service via time series analysis. Future Generation Computer Systems, 2016,68:275–288.
- [4] Chen L, Feng Y, Wu J, *et al.* An enhanced QoS prediction approach for service selection. In: Proc. of the IEEE Int'l Conf. on Services Computing (SCC 2011). Washington, 2011. 727–728.
- [5] Brier E, Clavier C, Olivier F. Correlation power analysis with a leakage model. LNCS, 2004,37(22):16–29.
- [6] Le TH, Clédière J, Canovas C, *et al.* A proposition for correlation power analysis enhancement. LNCS, 2006,4249(6):174–186.
- [7] Shao L, Zhang J, Wei Y, *et al.* Personalized QoS prediction for Web services via collaborative filtering. In: Proc. of the IEEE Int'l Conf. on Web Services. IEEE, 2007. 439–446.
- [8] Shao LS, Zhang J, Wei Y, *et al.* Web service QoS prediction. 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>
- [9] Wang X, Zhu J, Shen Y. Network-aware QoS forecasting for service composition using geolocation. IEEE Trans. on Services Computing, 2015,PP(99):630–643.
- [10] Fanjiang YY, Yang S, Kuo JY. Search based approach to forecasting QoS attributes of Web services using genetic programming. Information and Software Technology, 2016,80:158–174.
- [11] Hua ZB, Li M, Zhao JF, *et al.* Web service QoS forecasting approach based on time series analysis. Journal of Frontiers of Computer Science and Technology, 2013,7(3):218–226 (in Chinese with English abstract).
- [12] Li Z, Zhang B, Na J, *et al.* An approach for Web service QoS prediction based on service using information. In: Proc. of the Int'l Conf. on Service Sciences. IEEE, 2010. 324–328.
- [13] Liu KF, Wang H, Xu ZP. A Web service selection mechanism based on QoS prediction. Computer Technology and Development, 2007,17(8):103–105 (in Chinese with English abstract).
- [14] Reimers HE. Time Series Models for Business and Economic Forecasting. Cambridge University Press, 1998. 686–687.
- [15] Amin A, Colman A, Grunske L. An approach to forecasting QoS attributes of Web services based on ARIMA and GARCH models. In: Proc. of the IEEE Int'l Conf. on Web Services. IEEE, 2012. 74–81.
- [16] Ye Z, Mistry S, Bouguettaya A, *et al.* Long-term QoS-aware cloud service composition using multivariate time series analysis. IEEE Trans. on Services Computing, 2016,9(3):1–1.
- [17] Wang S, Hsu CH, Liang Z, *et al.* Multi-user Web service selection based on multi-QoS prediction. Information Systems Frontiers, 2014,16(1):143–152.
- [18] Wang X, Han M. Improved extreme learning machine for multivariate time series online sequential prediction☆. Engineering Applications of Artificial Intelligence, 2015,40:28–36.
- [19] Ming ZX, Liang NG. An improved RBF network on-line learning algorithm. In: Proc. of the Int'l Symp. on Information Science and Engineering. IEEE Computer Society, 2009. 547–552.
- [20] Takens F. Detecting Strange Attractors in Turbulence. Lecture Notes Math., 1981. 366–381.
- [21] Yin Y, Shang P. Forecasting traffic time series with multivariate prediction approach. Applied Mathematics & Computation, 2016, 291:266–278.
- [22] Rosenstein MT, Collins JJ, Luca CJD. Reconstruction expansion as a geometry-based framework for choosing proper delay times. Physica D Nonlinear Phenomena, 1993,73(1-2):82–98.
- [23] Lin JY, Huang ZP, Wang YK, *et al.* Modification of average displacement approach for selection of time-delay in phase space reconstruction of speech signals. Journal of National University of Defense Technology, 1999,3:59–62 (in Chinese with English abstract).
- [24] Bilski J, Smolag J, Žurada JM. Parallel approach to the levenberg-marquardt learning algorithm for feedforward neural networks. In: Proc. of the 14th Int'l Conf. Artificial Intelligence and Soft Computing (ICAISC 2015). Springer Int'l Publishing, 2015. 3–14.
- [25] Haykin BS. Neural Networks and Learning Machines. 3rd ed. Upper Saddle River, NJ, 2010. 120–135.
- [26] Sun J, Shen RM, Han P. An original RBF network learning algorithm. Chinese Journal of Computers, 2003,26(11):1562–1567 (in Chinese with English abstract).
- [27] Mani A, Nagarajan A. Understanding quality of service for Web services: Improving the performance of your Web services. 2002. <http://www-128.ibm.com/developerworks/ebservices/library/ws-quality.html>

- [28] Azzalini A, Farge M, Kai S. Nonlinear wavelet thresholding: A recursive approach to determine the optimal denoising threshold. *Applied & Computational Harmonic Analysis*, 2005, 18(18):177–185.
- [29] Yuan DB, Cui XM, Wang G, et al. Research on denoising of GPS data based on nonlinear wavelet transform threshold method. *Advanced Materials Research*, 2012, 926–936.
- [30] Han M, Liu Y, Xi J, et al. Noise smoothing for nonlinear time series using wavelet soft threshold. *IEEE Signal Processing Letters*, 2007, 14(1):62–65.
- [31] Zhang P, Sun Y, Li W, et al. A combinational QoS-prediction approach based on RBF neural network. In: Proc. of the IEEE Int'l Conf. on Services Computing. IEEE, 2016. 577–584.
- [32] Rojas I, Valenzuela O, Rojas F, et al. Soft-computing techniques and ARMA model for time series prediction. *Neurocomputing*, 2008, 71(4–6):519–537.

附中文参考文献:

- [1] 马友,王尚广,孙其博,等.一种综合考虑主客观权重的 Web 服务 QoS 度量算法.软件学报,2014,25(11):2473–2485. <http://www.jos.org.cn/1000-9825/4508.htm> [doi: 10.13328/j.cnki.jos.004508]
- [8] 邵凌霜,周立,赵俊峰,等.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>
- [11] 华哲邦,李萌,赵俊峰,等.基于时间序列分析的 Web Service QoS 预测方法.计算机科学与探索,2013,7(3):218–226. <http://fcst.ceaj.org/CN/abstract/abstract594.shtml>
- [13] 刘克非,王红,许作萍.一种基于服务质量预测的 Web 服务选择方法.计算机技术与发展,2007,17(8):103–105. <http://wenku.baidu.com/view/82a14b365901020207409c73.html?re=view>
- [23] 林嘉宇,黄芝平,王跃科,等.语音信号相空间重构中时间延迟选择的改进的平均位移法.国防科技大学学报,1999,3:59–62.
- [26] 孙健,申瑞民,韩鹏.一种新颖的径向基函数(RBF)网络学习算法.计算机学报,2003,26(11):1562–1567.



张鹏程(1981—),男,江苏滨海人,博士,副教授,CCF 高级会员,主要研究领域为软件建模、分析和验证技术。



吉顺慧(1987—),女,博士,讲师,CCF 专业会员,主要研究领域为软件建模、分析、测试与验证。



王丽艳(1992—),女,硕士,主要研究领域为多元时间序列预测。



李雯睿(1981—),女,博士,副教授,CCF 高级会员,主要研究领域为服务计算。