

基于残差修正 GM(1,1)模型的车流量预测

赵卓峰¹ 杨宗润²

(北方工业大学计算机学院 北京 100144)¹

(大规模流数据集成与分析技术北京市重点实验室 北京 100144)²

摘要 车流量预测是城市智能交通系统研究中的热难点问题之一,精确的车流量预测能有效地支持智能交通系统的发展,减少拥堵。同时车流量预测的精确度密切关系着居民的出行质量。然而车流量受诸多因素的不同程度的影响,具有一定程度的随机性、灰色性和不确定性,从城市交叉路口得到的车流量监控数据也具有一定程度的缺失和偏差,简单、准确且高效地预测车流量成为一个挑战。基于交叉路口采集到的车牌识别数据,通过对比经典 GM(1,1)得到的预测值与真实值计算出残差,用残差去修正计算模型进而得到修正 GM(1,1)模型,再用得到的修正模型迭代处理同一数据集,最后,数值稳定收敛且精度高于未修正模型的结果。

关键词 车流量预测,GM(1,1)灰色模型,残差

中图分类号 TP391 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2017.04.021

Traffic Flow Forecast Based on Residual Modification GM(1,1) Model

ZHAO Zhuo-feng¹ YANG Zong-run²

(School of Computer Science and Technology, North China University of Technology, Beijing 100144, China)¹

(Beijing Key Laboratory on Integration and Analysis of Large-scale Stream Data, Beijing 100144, China)²

Abstract Traffic flow prediction has been one of the core problems in urban transport system. Accurate and efficient traffic prediction can effectively support the urban transportation planning, effectively reduce traffic congestion and the waste of resources and emissions. The accuracy of vehicle traffic forecast is also closely related to the residents' travel quality. However, traffic is affected by many uncertain factors that has a certain degree of uncertainty, randomness and gray. The data from city intersection traffic monitors also has a certain degree of loss and deviation. Simply, accurately and efficiently predicting traffic is a problem. Using the data from monitors, through the prediction value of GM(1,1) model comparing with real value to compute residual, using residual to modify computing model to get modified GM(1,1) model, multiple iterations are used for the same data set, and the final results are stable and superior to the classic GM(1,1) model. Experiments show that compared with the classic GM(1,1) model, the improved GM(1,1) model to get the predicted values is more close to the real value. With the complexity of the classical algorithm, the calculation accuracy is improved to some extent.

Keywords Traffic flow forecast, Grey GM(1,1), Residual

1 问题背景

中国城市的机动车数量基本趋于饱和,道路系统承载的压力越来越大。由交通拥堵造成的危害巨大,如果不能快速处理,很容易导致拥堵的严重恶性循环,而高速发展的经济下居民快节奏的生活又增大了交通拥堵的外部成本,居民追求高质量的出行条件和低碳社会的形成给城市道路交通系统提出了更严峻的挑战。在这样的大环境和前提下,用最科学的方法最大限度地利用道路资源,对道路网交通流进行准确、快

速的预测,是当前智能交通系统发展的重要任务。

车流量的预测根据预测时间跨度的不同分为长期预测、中期预测和短期预测。长期预测一般以年为单位,中期预测一般以月、日和小时为单位,短期预测一般研究 5~15 分钟的车流量。短期预测的数据规律性相对较弱,随机误差干扰较强,具有高度的不确定性^[1]。车流量的预测根据预测对象可以分为对路段的车流量预测和对监测点的预测。车流量还可以根据预测数据分为应用浮动车辆数据的预测、感应线圈数据的预测和摄像头采集数据的预测。

到稿日期:2015-11-30 返修日期:2016-03-07 本文受北京市自然科学基金资助项目(4162021)资助。

赵卓峰(1977-),男,博士,副研究员,主要研究方向为流数据处理、交通大数据,E-mail: edzhao@ncut.edu.cn;杨宗润(1989-),男,硕士生,主要研究方向为分布式计算。

经过大量的研究,国内外很多方法已经被用于车流量预测。典型的方法主要有历史趋势法^[2]、灰度模型法^[3]、卡尔曼滤波法^[4]、非参数回归法^[5]和神经网络法^[6]等。历史趋势法在没有准确的交通流数据或没有紧急交通事件发生的情况下可以取得较好的预测效果。灰度模型法以 GM(1,1)模型为代表,预测模型简单但精确度有待提高。卡尔曼滤波法能得出对交通流相对满意的预测结果,但无法适应非线性变化的交通流。因此在回归模型的基础上,出现了非参数回归法和神经网络法等方法^[7]。非参数回归法适合非线性的动态变化系统,符合交通流的非线性特征,但此方法需要大量历史数据的支持以建立各个序列的内部联系,神经网络法过于依赖于初始值的选取,收敛速度慢。近年来也出现了应用到预测车流量领域的更多的算法,如支持向量机^[8]、高斯核函数^[9-10]、k-临近法^[11]和 ARIMA 预测算法^[12-13]等。

2 问题描述

车流量是指在单位时间内通过某个监测点或者路段的车辆数。车流量和很多因素相关联,例如天气、时间和人为因素等,这使得车流量具有极大程度的随机性,从而为车流量的预测增加了一定的难度。本文用到的车流量是指通过某个检测点的车流量。数据来自某城市主要道路安装的记录机动车车牌信息的智能摄像头,摄像头将拍摄的车牌照片、识别车牌信息整合成指定的数据结构并传送给数据系统,再以文本的形式储存在文件系统中^[14]。数据涉及到城区的所有检测点,数据的总规模较大,对城市的每个检测点的车流量进行预测需要简单且相对精确的方法。灰色 GM(1,1)模型适用的随机模糊性和灰色性都符合车流量的特点,且预测简单,因此把灰色系统应用到车流量的短期预测上是可行且可以实现的。为了适当提高预测精度,在经典的灰度 GM(1,1)模型的基础上进行改进,提出了基于残差修正的 GM(1,1)模型。

著名学者邓聚龙在 20 世纪 90 年代初开辟了一门新学科,即灰色系统理论^[15],其通过研究少量确切信息的数据样本,挖掘出未知的有用的信息,以正确认知系统的特性,并以此进行科学预测。其基本思想是通过逐项累加把原始数据生成次级序列,利用生成的次级序列分析数据的特征,对逐次变换后的次级序列建立微分方程模型,其中所建立的单阶单变量微分方程称为 GM(1,1)模型。

3 基于残差修正 GM(1,1)模型的车流量预测

3.1 GM(1,1)模型

设有初级数据 $x^{(0)}(t)(t=1,2,\dots,n)$,将其通过逐次累加转化为次级序列 $x^{(1)}(t)$,得到如下形式的微分方程:

$$\frac{dx^{(1)}}{dt} - ax^{(1)} = b \quad (1)$$

用最小二乘法求解方程(1)中的系数 a 和 b ,并将 a 和 b 代入方程(1)中,方程(1)可以变换为:

$$\hat{x}^{(1)}(t+1) = (x^{(0)}(1) - \frac{b}{a})e^{-at} + \frac{b}{a} \quad (2)$$

对上述变换后的方程(2)得到的项做逆向累加,得到还原以后的新的预测序列:

$$\hat{x}^{(0)}(t+1) = \hat{x}^{(1)}(t+1) - \hat{x}^{(1)}(t) \quad (3)$$

其中, $t=1,2,\dots,n$ 。

3.2 残差修正的 GM(1,1)模型

定义残差序列为:

$$\epsilon^{(0)}(t) = \hat{x}^{(0)}(t) - x^{(0)}(t) \quad (4)$$

将预测得到的残差序列作为原始数据的修正项,通过修正原始序列得到一组新的数据,具体公式为:

$$y^{(0)}(t) = x^{(0)}(t) - \epsilon^{(0)}(t) \quad (5)$$

其中, $\epsilon^{(0)}(t)$ 是一次预测后产生的残差序列中符号一致的项累加以后求均值的结果。

对修正以后的原始序列 $y^{(0)}(t)$ 做逐次累加得到新的次级序列 $y^{(1)}(t)$,并用新的次级序列建立新的微分方程:

$$\frac{dy^{(1)}}{dt} - ay^{(1)} = b \quad (6)$$

分别求解上述微分方程中的系数 a 和 b ,将其代入微分方程(6)中得到代换后的变形方程:

$$\hat{y}^{(1)}(t+1) = (y^{(0)}(1) - \frac{b}{a})e^{-at} + \frac{b}{a} \quad (7)$$

用方程(7)做累减得到原始数据的预测值:

$$\hat{y}^{(0)}(t+1) = \hat{y}^{(1)}(t+1) - \hat{y}^{(1)}(t) \quad (8)$$

3.3 车流量预测方法

用上述的残差修正模型进行短时车流量预测的方法描述如下。用得到的车流量序列进行逐项循环累加,得到新的生成序列,建立微分方程,用最小二乘法求解其中的参数,得到关于累加序列的方程,逆向计算原始序列的预测值,计算原始序列的残差,对相同符号的残差序列求残差均值,将其分别加到对应的原始序列上,得到新的序列,按照新的序列重复上述过程,直到预测结果收敛。算法的简单流程图如图 1 所示。

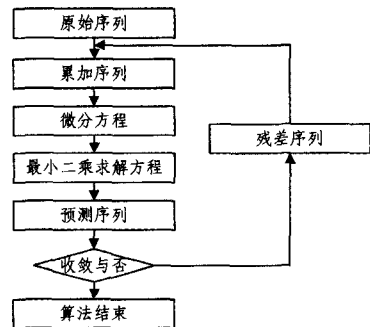


图 1 残差修正模型的流程图

与经典的 GM(1,1)模型对比,改进的算法在单次的计算中增加了计算原始残差、修正残差和修正原始序列这 3 个步骤。这 3 个计算过程的时间复杂度都为 $O(n)$,而用最小二乘法计算 GM(1,1)模型的时间复杂度为 $O(n^2)$,所修正算法的时间复杂度和经典算法的复杂度一样,都是 $O(n^2)$,因此单次计算效率并未下降。如果循环执行改进算法,最终其效率是经典算法的循环次数倍,而这和输入的数据有较大的关系,若是相对平稳的原始序列,得到的预测结果很快会收敛在误差控制的范围内,则整个算法的效率相对较低。

4 模型评价

灰度模型的精度检验方法一般包括关联度检验、相对误差检验法和后验差检验3种方法。针对经典GM(1,1)模型和残差修正GM(1,1)模型,本文选用相对误差检验法和后验差检验法对模型进行检验。

4.1 相对误差检验法

假设原始车流量的原始序列为 $x^{(0)}(t)$,由经典的GM(1,1)模型得出的车流量预测序列为 $\hat{x}^{(0)}(t)$,按照式(4)定义的残差,根据式(9)计算车流量预测相对误差。

$$rel(t) = \frac{\epsilon(t)}{x^{(0)}(t)}, t=1, 2, \dots, n \quad (9)$$

按照式(10)计算车流量预测平均相对误差。

$$rel = \frac{1}{n} \left| \sum_{t=1}^n rel(t) \right|, t=1, 2, \dots, n \quad (10)$$

4.2 后验差检验法

假设车流量原始序列为 $x^{(0)}(t)$,由GM(1,1)预测模型得出的车流量预测序列为 $\hat{x}^{(0)}(t)$,相应车流量残差序列为 $\epsilon^{(0)}(t)$,分别用 S_1^2 与 S_2^2 定义原始序列与残差序列的方差:

$$S_1^2 = \frac{1}{n} \sum_{t=1}^n [x^{(0)}(t) - \bar{x}]^2 \quad (11)$$

$$S_2^2 = \frac{1}{n} \sum_{t=1}^n [\epsilon^{(0)}(t) - \bar{\epsilon}]^2 \quad (12)$$

其中, $\bar{x} = \frac{1}{n} \sum_{t=1}^n x^{(0)}(t)$, $\bar{\epsilon} = \frac{1}{n} \sum_{t=1}^n \epsilon^{(0)}(t)$

可以定义后验差比的形式为:

$$c = \sqrt{\frac{S_2^2}{S_1^2}} \quad (13)$$

相对应的小误差事件概率的形式为:

$$p = P\{|\epsilon^{(0)}(t) - \bar{\epsilon}| < 0.6745S_1\} \quad (14)$$

后验差比值 C 和小误差事件概率 P 是本检验法需考虑的两个关键因子,因子 C 越小模型精度越高,预测的车流量值越接近真实值。相反,指标 P 越小模型精度越低,预测的车流量值越偏离真实值。一般的情况下, S_1 越大表示初始数据分布的离散性也越大, S_2 越小表示残差分布的离散性也越小。

表1列出了精度对照情况,可以根据这两个指数把精度等级划分为好、合格、勉强和不合格4个等级。一般地,把模型的精度界定为 P 与 C 纵向比较的最大值所在的精度。

表1 精度对照表

精度等级	均方差比值 C	小误差事件概率 P
1级(好)	$C \leq 0.35$	$0.95 \leq P$
2级(合格)	$0.35 < C \leq 0.5$	$0.80 \leq P < 0.95$
3级(勉强)	$0.5 < C \leq 0.65$	$0.70 \leq P < 0.80$
4级(不合格)	$0.65 < C$	$P < 0.70$

5 实验及分析

实验所用的验证环境是 windows7 系统下的 matlab7.0。随机从某市的200多个监测点中选取10个监测点,得到这些监测点某一天不同时段的车流量序列,分别对10个车流量序列应用经典预测算法和修正算法对比预测结果。得到如下某

一序列:55,50,55,65,74,79,73,78,其代表其中一个监测点的车流量数,每个项代表5分钟的车辆数,如55代表5分钟内通过监测点的车辆数为55。使用上述10组数据序列作为样本数据,用经典GM(1,1)模型和残差修正的模型分别进行预测。其中每组数据除去最后一项后建立模型,用得到的预测结果对比每一组数据的最后一项,分析预测准确性。

根据上述的步骤对序列项建立模型,得到随时间变化的函数:

$$x(t+1) = 634.4796 \exp(0.080868t) - 579.4796$$

将 t 值带入上述函数,得到相应的预测项,对比初始数据并按照相应的公式计算残差、相对误差和绝对误差。经典模型预测结果如表2所列。

表2 经典模型预测结果

时间/ t	预测值	绝对误差	相对误差	残差
0	55	0	0	0
1	53.4407	3.4407	0.0688	3.4407
2	57.9419	2.9419	0.0535	2.9419
3	62.8222	2.1778	0.0335	-2.1770
4	68.1136	5.8864	0.0795	-5.8860
5	73.8506	5.1494	0.0652	-5.1490
6	80.0709	7.0709	0.0969	7.0709

将表2中的数据按照式(10)一式(13)分别计算相应的值,可以得到平均相对误差为0.0568,该值小于0.1,误差可以接受,均方差比值 C 为21.3491%,小误差事件概率为100%。对比表1得出结论:该模型为一级精度模型,可以用于短期预测,但是得到第8个时间点的车流量预测值为86.8152,绝对误差为8.8152,相对误差11.30%,预测值的误差相对较大。

5.1 用修正的模型进行预测

用修正模型对序列建立模型,得到随时间变化的函数:

$$x(t+1) = 568.5697 \exp(0.088137t) - 513.5697$$

用上述的方程逆向计算原始序列的预测值,然后分别计算其他几个验证项,如表3所列。

表3 修正模型第一次预测结果

时间/ t	预测值	绝对误差	相对误差	残差
0	55.0000	0	0	0
1	54.5368	4.5368	0.0907	4.5368
2	58.6807	3.6807	0.0669	3.6807
3	63.1394	1.8606	0.0286	-1.8600
4	67.9369	6.0631	0.0819	-6.0630
5	73.0989	5.9011	0.0747	-5.9010
6	78.6532	5.6532	0.0774	5.6532

将表3的结果按公式计算所得平均相对误差为0.0600,该值小于0.1,误差可接受,均方差比为24.4606%,小误差事件概率为100%,该模型为一级精度模型,可用于短期预测;并且得到第8个时间点的车流量预测值为84.6289,绝对误差为6.6289,相对误差为8.50%,预测效果优于经典的模型。

再用改进的模型进行一次预测计算,得到如下随时间变化的函数:

$$x(t+1) = 720.7201 \exp(0.072959t) - 665.7201$$

按照上述方程计算预测值和其他验证项结果,如表4所列。

表 4 修正模型第二次预测结果

时间/t	预测值	绝对误差	相对误差	残差
0	55	0	0	0
1	54.5490	4.5490	0.0910	4.5490
2	58.6777	3.6777	0.0669	3.6777
3	63.1188	1.8812	0.0289	1.8810
4	67.8961	6.1039	0.0825	-6.1040
5	73.0349	5.9651	0.0755	-5.9650
6	78.5627	5.5627	0.0762	5.5627

表 5 两种方法预测结果的相对误差对比

相对误差	1	2	3	4	5	6	7	8	9
经典算法	0.1134	0.1065	0.1242	0.1461	0.0857	0.1975	0.1572	0.1372	0.2531
修正算法	0.08324	0.0874	0.0732	0.0856	0.0606	0.0902	0.0821	0.0843	0.1342

基于表 5 的预测结果分别计算 9 组数据的平均相对误差,经典 GM(1,1)模型预测的平均相对误差为 0.1468,残差修正 GM(1,1)模型预测的平均相对误差为 0.0868,残差修正模型的平均相对误差小于经典 GM(1,1)模型的平均相对误差,对不同的数据残差修正模型的预测精度有不同程度的提升。

5.2 结果分析

原数据与预测数据的对比情况如图 2 所示。




图 2 原数据与预测数据的对比

从图 2 的实验对比可以看出,同一组初始数据在用改进和修正以后的 GM(1,1)模型进行一定次数的连续计算后,预测值的曲线会大量重合,可以在保持相对误差与经典模型相差不大的情况下使得均方差比值、小误差概率和预测值都得到稳定的收敛,并且能使预测值有效地逼近真实值。对比经典模型,修正的模型具有更高层次的敏感性以及保持均方差比值基本一致的前提下使预测结果更逼近真实数值,且无数值震荡现象出现,因此可以说修正模型在一定程度上优化了经典模型。

结束语 本文改进于经典的 GM(1,1)模型,用经典模型得到的残差去修正初始数据,用修正的初始数据再进行预测,循环此过程,最后得到最接近真实值的预测值。通过仿真实验将修正的模型与经典的模型进行对比,修正的模型可以对同一数据进行多次预测,为得到的预测值的后续处理提供了更宽的思路;同时,改进的模型对数据没有依赖性,可适用于同类型的相关数据。

参考文献

[1] CHEN Y, XIAO X P. Research on short time traffic flow forecasting model based on fraction accumulation generation[D]. Wuhan, Wuhan University of Technology, 2014; 8-9. (in Chinese)

将表 4 的结果按公式计算平均相对误差,结果为 0.0601 小于 0.1,均方差比值 C 为 24.6%,小误差事件概率为 100%,一级精度模型达到了预期的效果,且得到第 8 个时间点的车流量预测值为 84.5082,绝对误差为 6.6289,相对误差为 8.34%,预测结果最接近真实数值,优于上次修正得到的结果。

为了验证算法对数据没有依赖性,对选取的其他 9 组数据分别应用经典算法和修正算法进行计算,用最后得到的预测结果计算相对误差,如表 5 所列。

nese)
陈野,肖新平.基于分数阶累加生成的短时交通流预测模型研究[D].武汉:武汉理工大学,2014;8-9.
[2] STEPHANEDES V J, MICHALOPOULOS P G, PLUM R A. Improved estimation of traffic flow for real time control[J]. Transportation Research Record, 1981, 79(5): 28-39.
[3] CHEN S Y, CHEN J S. Application of A Novel Grey Model to Traffic Flow Prediction[J]. Journal of highway and transportation research and development, 2004, 21(2): 80-83. (in Chinese)
陈淑燕,陈家胜.一种改进的灰色模型在交通量预测中的应用[J].公路交通科技,2004,21(2):80-83.
[4] SHEN G J, ZHU Y, QIAN X J, et al. Short-term traffic flow forecasting based on hybrid model[J]. Journal of Nanjing University of Science and Technology, 2014, 38(2): 246-251. (in Chinese)
沈国江,朱芸,钱晓杰,等.短时交通流组合模型预测[J].南京理工大学学报,2014,38(2):246-251.
[5] OKUTANI I, STEPHANEDES Y J. Dynamic prediction of traffic volume through Kalman filtering theory[J]. Transportation Research. Part B: Methodological, 1984, 18(1): 1-11.
[6] GUAN S, GAO J W, ZHANG B, et al. Traffic Flow Prediction Based on K-Means Clustering Algorithm and RBF Neural Network[J]. Journal of Qingdao University(Engineering & Technology Edition), 2014, 29(2): 20-23. (in Chinese)
管硕,高军伟,张彬,等.基于 K-均值聚类算法 RBF 神经网络交通流预测[J].青岛大学学报(工程技术版),2014,29(2):20-23.
[7] 邵春福,熊志华.路网短时交通需求预测理论、方法及应用[M].北京:清华大学出版社,2011;8-9
[8] YU R, WANG G X, ZHENG J Y, et al. Urban Road Traffic Condition Pattern Recognition Based on Support Vector Machine[J]. Journal of Transportation Systems Engineering and Information Technology, 2013, 29(2): 130-136. (in Chinese)
于荣,王国祥,郑继媛,等.基于支持向量机的城市道路交通状态模式识别研究[J].交通运输系统工程与信息,2013,29(2):130-136
[9] LEI S M, JIA X J, YU Z Y. Short term traffic flow forecast based on gauss kernel function[J]. Journal of MUC(Natural Sciences Edition), 2013, 33(3): 82-87. (in Chinese)

推理,完成行为预测、故障定位等任务。针对程序的多故障,Abreu 等人^[6]提出了一种基于观测值的模型,其通过计算候选诊断的后验概率来进行软件诊断,候选诊断的计算使用了一种启发式的最小碰集算法。此外,针对单故障软件诊断,已有的基于模型的诊断技术包括:通过插桩源程序和学习执行测试用例时产生的数据信息提出概率程序依赖图^[3];根据程序指令建立的基于叶斯网络的错误流图^[4]。这两种方法都没有强调处理多故障的能力。

结束语 本文提出了一种基于 TBFL 技术和无向网络的概率推理技术。针对多故障程序,在建立 FCG 时使用 PDG 来发现故障关联,并使用 TBFL 技术来计算 FCG 的概率分布,最后通过 FCG 上的深层概率推理计算得到语句的可疑度排序。通过采用不同大小的测试用例进行实验对比分析,验证了 FCG 方法对多故障程序的有效性。本文采用二进制方式来表示语句执行信息,但是带循环语句的程序可能存在执行次数大于 1 的语句,所以在将来的工作中将考虑采用整数代替二进制来表示语句的执行次数。

参 考 文 献

- [1] JONES J A, HARROLD M J. Empirical evaluation of the tarantula automatic fault-localization technique[C]// Proceedings of the ACM International Conference on Automated Software Engineering. New York, USA, 2005; 273-282.
- [2] MASRI W, ABOU-ASS R, EL-GHALI M, et al. An empirical study of the factors that reduce the effectiveness of coverage-based fault localization [C]// Proceedings of the 2nd International Workshop on Defects in Large Software Systems. Chicago, Illinois, USA, 2009; 1-5.
- [3] BAAH G K, PODGURSKI A, HARROLD M J. The Probabilistic Program Dependence Graph and Its Application to Fault Diagnosis [J]. IEEE Transactions on Software Engineering, 2010, 36; 528-545.
- [4] FENG M, GUPTA R. Learning universal probabilistic models for fault localization [C]// Proceedings of ACM SIGPLAN-SIGSOFT Workshop on Program Analysis for Software Tools and Engineering. Toronto, Ontario, Canada, 2010; 81-88.
- [5] ABREU R, ZOETEWEIJ P, GOLSTEIJN R, et al. A practical evaluation of spectrum-based fault localization [J]. Journal of Systems and Software, 2009, 82(11); 1780-1792.
- [6] ABREU R, ZOETEWEIJ P, VAN Gemund A J C. A New Bayesian Approach to Multiple Intermittent Fault Diagnosis[C]// Proceedings of International Joint Conference on Artificial Intelligence. San Francisco, 2009; 653-658.
- [7] DIGIUSEPPE N, JONES J A. On the influence of multiple faults on coverage-based fault localization[C]// Proceedings of the International Symposium on Software Testing and Analysis. ACM, 2011; 210-220.
- [8] YU K, LIN M, GAO Q, et al. Locating faults using multiple spectra-specific models [C]// Proceedings of ACM Symposium on Applied Computing. 2011; 1404-1410.
- [9] PEARL J. Probabilistic reasoning in intelligent systems; networks of plausible inference [M]. Morgan Kaufmann Publishers, 1988.
- [10] KOLLER D, Friedman N. Probabilistic Graphical Models: Principles and Techniques [M]. The MIT Press, 2009.
- [11] BAO X A, XIE X M, ZHANG N, et al. Optimized Software Testing Strategy Based on the Defect Correlation Markov Model [J]. Journal of Software, 2015, 26(1); 14-25. (in Chinese)
- 包晓安, 谢晓鸣, 张娜, 等. 基于缺陷关联度的 Markov 模型软件优化测试策略[J]. 软件学报, 2015, 26(1); 14-25.
- [12] WOTAWA F. Fault Localization Based on Dynamic Slicing and Hitting-Set Computation [C]// The 10th International Conference on Quality Software, 2010. 2010; 161-170.
- [13] WEN W Z, LI B X, SUN X B, et al. Technique of Software Fault Localization Based on Hierarchical Slicing Spectrum [J]. Journal of Software, 2013, 24(5); 977-992. (in Chinese)
- 文万志, 李必信, 孙小兵, 等. 一种基于层次切片谱的软件错误定位技术[J]. 软件学报, 2013, 24(5); 977-992.
- [14] SUN S, YU G, ZHANG C. Short-term traffic flow forecasting using Sampling Markov Chain method with incomplete data[C]// Intelligent Vehicles Symposium, 2004 IEEE. IEEE, 2004; 437-441.
- [15] ZHANG S, ZHAO Z F, DING W L, et al. Urban Road Trip Time Measured Calculation Based on Map-Reduce[J]. Computer and Digital Engineering, 2014, 42(9); 1542-1546. (in Chinese)
- 张帅, 赵卓峰, 丁维龙, 等. 基于 MapReduce 的城市道路旅行时间实测计算[J]. 计算机与数字工程, 2014, 42(9); 1542-1546.
- [15] 邓聚龙. 灰预测与灰决策(修订版)[M]. 武汉: 华中科技大学出版社, 2002.

(上接第 99 页)

雷少梅, 贾旭杰, 于在洋. 基于高斯核函数的短时交通流量预测 [J]. 中央民族大学学报(自然科学版), 2013, 33(3); 82-87.

[10] XIE Y, ZHAO K, SUN Y, et al. Gaussian Processes for Short-Term Traffic Volume Forecasting[J]. Transportation Research Record; Journal of the Transportation Research Board, 2010, 2165(-1); 69-78.

[11] YU B, WU S H, WANG M H, et al. K nearest neighbor short-term traffic flow forecasting model [J]. Journal of Traffic and Transportation Engineering, 2012, 12(2); 105-111. (in Chinese)

于滨, 邹珊华, 王明华, 等. K-临近短时交通预测模型[J]. 交通运输工程学报, 2012, 12(2); 105-111.

[12] WILLIAMS B M, HOEL L A. Modeling and Forecasting Vehicular Traffic Flow as a Seasonal ARIMA Process; Theoretical

Basis and Empirical Results[J]. Journal of Transportation Engineering, 2014, 129(6); 664-672.

[13] SUN S, YU G, ZHANG C. Short-term traffic flow forecasting using Sampling Markov Chain method with incomplete data[C]// Intelligent Vehicles Symposium, 2004 IEEE. IEEE, 2004; 437-441.

[14] ZHANG S, ZHAO Z F, DING W L, et al. Urban Road Trip Time Measured Calculation Based on Map-Reduce[J]. Computer and Digital Engineering, 2014, 42(9); 1542-1546. (in Chinese)

张帅, 赵卓峰, 丁维龙, 等. 基于 MapReduce 的城市道路旅行时间实测计算[J]. 计算机与数字工程, 2014, 42(9); 1542-1546.

[15] 邓聚龙. 灰预测与灰决策(修订版)[M]. 武汉: 华中科技大学出版社, 2002.