

文章编号:1671-1637(2012)02-0105-07

K近邻短时交通流预测模型

于 滨¹, 邬珊华¹, 王明华¹, 赵志宏²

(1. 大连海事大学 交通运输管理学院, 辽宁 大连 116026; 2. 长安大学 信息工程学院, 陕西 西安 710064)

摘 要:为了准确预测道路短时交通流, 构建了基于K近邻算法的短时交通流预测模型。分析了K近邻算法的时间和空间参数, 提出4种状态向量组合的K近邻模型: 时间维度模型、上游路段-时间维度模型、下游路段-时间维度模型与时空参数模型。以贵州省贵阳市出租车的GPS数据对几种K近邻模型进行了检验。分析结果表明: 带有时空参数的K近邻模型具有更高的预测精度, 其预测误差最小, 平均为7.26%。基于指数权重的距离度量方式能更精确的选择近邻, 其预测误差最小, 平均为5.57%。与神经网络和历史平均模型相比, 带有指数权重的K近邻模型具有更好的预测精度, 平均预测误差仅为9.43%。可见, 带有时空参数与指数权重的K近邻模型可作为道路短时交通流预测的有效手段。

关键词: 交通信息工程; 短时交通流预测; K近邻模型; 时空参数; 指数权重

中图分类号: U491.14

文献标志码: A

K-nearest neighbor model of short-term traffic flow forecast

YU Bin¹, WU Shan-hua¹, WANG Ming-hua¹, ZHAO Zhi-hong²

(1. School of Transportation Management, Dalian Maritime University, Dalian 116026, Liaoning, China;

2. School of Information Engineering, Chang'an University, Xi'an 710064, Shaanxi, China)

Abstract: In order to accurately forecast the short-term traffic flow, a K-nearest neighbor (K-NN) model was set up. The time and space parameters of the K-NN model were analyzed. Based on four different combinations of state vectors, the time dimension model, upstream section-time dimension model, downstream section-time dimension model and space-time dimension model were proposed. The four different models were validated by using the GPS data from taxis of Guiyang. Analysis result indicates that the K-NN model with both space and time parameters has highest forecasting precision than the other three models, and its average prediction error is about 7.26%. The distance measuring mode with exponent weight has higher accuracy in choosing the nearest neighbors, and its average prediction error is about 5.57%. The predicting performance of improved K-NN model with exponent weight and space-time parameters is best compared with the artificial neural network model and the historical average model, and its average prediction error is only 9.43%. So the improved K-NN model is an effective way for forecasting short-term traffic flow. 2 tabs, 10 figs, 16 refs.

Key words: traffic information engineering; short-term traffic flow forecast; K-nearest neighbor model; space-time parameters; exponent weight

Author resume: YU Bin(1977-), male, associate professor, PhD, +86-411-84726756, yubinyb@

收稿日期: 2011-10-29

基金项目: 国家自然科学基金项目(51108053); 中国博士后科学基金项目(201003611); 中央高校基本科研业务费专项资金项目(2011ZC029, 2011QN037, CHD2011JC056)

作者简介: 于 滨(1977-), 男, 辽宁大连人, 大连海事大学副教授, 工学博士, 从事智能交通系统研究。

163.com.

0 引 言

短时交通流预测是智能交通系统研究中的重要内容之一。实时、准确的交通流预测是实现交通控制、诱导和提供实时交通信息服务的关键^[1]。目前国内对于短时交通流预测方法的研究大体可分为两类^[2]:一类是以传统数学和物理为基础的预测方法,包括历史平均模型、时间序列模型^[3]、卡尔曼滤波模型^[4-5]以及指数平滑模型等;另一类是无数学模型的预测方法,包括神经网络^[6]、非参数回归^[7]、支持向量机^[8-9]等。由于城市交通状态变化的不确定性、非线性和复杂性,有学者应用交通流模型来阐释交通流的动态变化规律,并以该规律来预测交通流的演化,从而实现短时交通流的预测,例如干宏程等运用宏观交通流模型预测路径行程时间^[10]。但是,交通流模型的构造相对复杂,在应用上具有一定难度。由于基于确定数学模型的预测方法在模型构建和求解上都存在困难,难以满足实际应用中实时性、准确性的需要^[11]。相对而言,无数学模型的预测方法,如神经网络、支持向量机等,不需构建复杂的数学模型,预测精度也能满足智能交通系统的要求,但这类方法需要对参数做耗时的调整,且移植性较差。非参数回归是另一类无数学模型的预测方法^[12-13],不需要任何先验知识,只需足够的历史数据,新观测数据可以方便地加入到模型中,且算法具有良好的数据挖掘和移植性能^[14]。

K 近邻是非参数回归中最常用的方法之一,本文拟采用 K 近邻方法对城市道路短时交通状况进行预测。城市道路的交通状况不仅与历史时段的交通状况密切相关,也受上、下游路段交通状况的影响。目前,很多短时交通流预测方面的研究都着重从时间维度的角度出发;Smith 等针对描述交通状态的时间间隔研究了不同取值对预测结果的影响^[7];翁剑成等以相邻时刻的速度变量为状态向量,对快速路行程速度进行了预测^[11];张涛等以相邻 4 个时间间隔的流量和占有率数据为状态向量,对短时交通流进行了预测,并取得了良好的效果^[14];Smith 等使用连续 5 个月的观察数据来预测美国华盛顿附近一条环形公路的交通流量^[15];Yu 等以当前时刻前几个时间点的数据来预测公交系统运行时间^[16]。这类研究着重于目标路段未来时段的交通状况与历史时段的关系,而忽略了空间维度,即上下

游路段的交通状况对目标路段的影响,因此,本文拟对常用的 K 近邻方法进行改进,结合时间维度和空间维度等参数以提高预测精度。另外,随着出租车 GPS 设备的推广,GPS 数据可作为获取交通流原始数据的另一种渠道,采用浮动车的准实时信息预测成为可能。本文基于贵州省贵阳市中华路出租车运行的 GPS 数据,构建了基于时空参数的 K 近邻短时交通流预测模型,通过设置不同的状态向量,研究各时空参数对模型预测精度的影响。

1 K 近邻预测模型

构建 K 近邻短时交通流预测模型的基本流程如下:首先,构建具有较大容量且有代表性的历史数据库;其次,设定模型的相关要素,包括状态向量、距离度量方式、近邻个数 K 和预测算法等,其中状态向量、距离度量方式和近邻个数 K 构成了模型的搜索机制;最后,根据输入的当前观测数值和搜索机制,从历史数据库中找到与当前实时观测数据相匹配的近邻,利用预测算法得到下一时刻的交通流速度。模型的预测精度与以下 4 个要素密切相关。

1.1 状态向量

状态向量是进行当前数据与历史数据比较的标准,一般选取与预测对象最为相关的因素,以平衡预测精度和运行时间两者的要求。

1.2 距离度量方式

距离度量方式用于度量历史数据库中各个样本数据与当前数据的近似程度,采用欧式距离作为度量指标

$$d_i = \sqrt{\sum_j w_j (V_j - V_{ji})^2} \quad (1)$$

式中: d_i 为当前数据与历史数据库中第 i 组数据的距离; w_j 为当前数据中第 j 个子项的权重; V_j 为当前数据中第 j 个子项的数值; V_{ji} 为第 i 组历史数据中第 j 个子项的数值。

1.3 近邻个数

近邻个数 K 表示从历史数据库中选取与当前数据相似的数据组数。 K 值的选取与样本数据有关, K 值过大或过小都会影响预测精度。

1.4 预测算法

预测算法是用于描述如何利用搜索到的 K 组近邻预测下一时刻的交通流状态

$$S_m(t+1) = \frac{\sum_{k=1}^K d_k^{-1} S'_k(t+1)}{\sum_{k=1}^K d_k^{-1}} \quad (2)$$

式中: d_k 为当前数据与第 k 个近邻的距离; $S_m(t+1)$ 为第 m 个路段第 $t+1$ 时段的平均车速; $S'_k(t+1)$ 为历史数据库中搜索到的第 k 个近邻所对应的第 $t+1$ 时段的平均车速。

2 K近邻改进模型

本文基于时空参数的模型改进主要体现在两方面:一是设置状态向量时考虑了时间维度和空间维度;二是采用带权重的距离度量方式,考虑了不同分量对预测时段交通状况影响的差异程度。

2.1 基于时空参数的状态向量

在城市道路中,每一路段都不是孤立存在的。无论上游还是下游路段发生拥堵,都必然会影响当前路段的交通状况。理论上,将时间维度和空间维度结合起来进行考虑,可以增加 K 近邻模型的预测精度。基于此,本文构建了基于时空参数的 K 近邻改进模型,其预测机理分别见图 1、2。




图1 基于时间维度的预测机理

Fig. 1 Prediction mechanism based on time dimension




图2 基于空间维度的预测机理

Fig. 2 Prediction mechanism based on space dimension

在图 1、2 中,假设目标路段为 m ,预测时段为 $t+1$ 。从时间维度看,路段 m 在 $t+1$ 时段的平均车速 $S_m(t+1)$ 与该路段前 $n+1$ 个历史时段的平均车速 $S_m(t)$ 、 $S_m(t-1)$ 、 \dots 、 $S_m(t-n)$ 密切相关。从空间维度看, $S_m(t+1)$ 与上、下游路段在 t 时段的平均车速 $S_{m-1}(t)$ 、 $S_{m+1}(t)$ 也存在一定的关系,因此, $S_m(t+1)$ 可通过这两方面预测得出,其他路段的预

测机理可依次类推。

理论上,与仅考虑时间维度的状态向量相比,同时考虑时间维度和空间维度的状态向量在模型预测中会呈现更高的预测精度,因为它能搜索到与当前实时输入数据更相似、质量更高的近邻。为比较这两类状态向量预测效果的差异,本文构建了基于不同状态向量的 4 种 K 近邻模型。4 种状态向量的构成见表 1。

表1 四种状态向量

Tab. 1 Four state vectors

状态向量	上游路段	下游路段	时间维度
时间维度			✓
上游路段-时间维度	✓		✓
下游路段-时间维度		✓	✓
时空参数	✓	✓	✓

2.1.1 时间维度模型

该模型只考虑时间维度的状态向量,在目标路段 m 上,预测 $t+1$ 时段的平均车速,只考虑该路段历史时段的平均车速。基于该预测模型建立的状态向量为 $(S_m(t), S_m(t-1), S'_m(t), S'_m(t-1))$,其中 $S'_m(t)$ 、 $S'_m(t-1)$ 分别为历史数据库中目标路段当前时段和前一时段的运行速度。

2.1.2 上游路段-时间维度模型

该模型在考虑时间维度的基础上,还考虑了上游路段(路段 $m-1$)的平均车速。基于该预测模型建立的状态向量为 $(S_m(t), S_m(t-1), S_{m-1}(t), S'_m(t), S'_m(t-1), S'_{m-1}(t))$ 。

2.1.3 下游路段-时间维度模型

该模型在考虑时间维度的基础上,还考虑了下游路段(路段 $m+1$)的平均车速。基于该预测模型建立的状态向量为 $(S_m(t), S_m(t-1), S_{m+1}(t), S'_m(t), S'_m(t-1), S'_{m+1}(t))$ 。

2.1.4 时空参数模型

该模型同时考虑了时间维度和空间维度的状态向量,搜集的数据更接近当前实时输入数据,从理论上说,带有时空参数的预测模型具有更高的预测精度。基于该预测模型建立的状态向量为 $(S_m(t), S_m(t-1), S_{m-1}(t), S_{m+1}(t), S'_m(t), S'_m(t-1), S'_{m-1}(t), S'_{m+1}(t))$ 。

2.2 带权重的距离度量方式

由于道路交通系统的时变性较强,同一路段在不同历史时段内的交通状况差别很大,在预测未来时段交通状况中的重要程度也各不相同。理论上,在搜索近邻过程中,如果对描述近邻近似程度的距

离度量方式采用带权重的方法,可能会搜索到与当前实时输入数据更相似、质量更高的近邻,因此,本文对状态向量中涉及时间维度的各个分量采用两种距离度量方式:相关系数权重法和指数权重法。

2.2.1 相关系数权重法

相关系数权重法是根据不同时段历史数据与预测时段数据间的相关系数,确定该时段在预测未来时段交通状态时的重要程度。基于相关系数权重的距离度量方式见图 3,将 $t+1$ 时段作为目标时段,其中 ω_0 为 t 时段的历史数据与 $t+1$ 时段数据的相关系数, ω_n 为 $t-n$ 时段的历史数据与 $t+1$ 时段数据的相关系数。




图 3 相关系数权重法

Fig. 3 Correlation coefficient weighting method

2.2.2 指数权重法。

指数权重法是通过各时段与预测时段的间隔确定各个分量的权重,选择的权重标准为 $(\frac{1}{2}, \frac{1}{4}, \dots, \frac{1}{2^{(n+1)}})$ 。基于指数权重的距离度量方式见图 4,该方法认为:距离目标时段($t+1$ 时段)越近的时段,其历史数据对目标时段的影响越大,其相应赋予的权重越高(例如图 4 中 t 时段的权重即为最大权重 $1/2$),其后时段数据的权重依次降低。




图 4 指数权重法

Fig. 4 Exponent weighting method

3 计算结果分析

3.1 数据获取与处理

选取贵州省贵阳市中华路上的 3 个路段为研究对象,即黔灵路—延安路路段、延安路—省府西路路段和省府西路—中山路路段。3 个路段的空间位置及信息见图 5,4 个相关交叉口的信号周期均为 130 s。

选取晚高峰(16:30~18:00)为研究时段,于 2011-04-11 至 2011-04-23 的工作日期间,收集 100 veh 出租车在研究时段的 GPS 信息(包括车牌




图 5 研究路段信息

Fig. 5 Informations of research road sections

号、司机工号、经度、纬度、运行速度、运行方向以及时间等)。通过对 GPS 异常数据的处理,共获得 217 564 组有效数据。为了统计各路段出租车的运行速度,首先需要将这些数据进行定位,出租车 GPS 信息与卫星地图的匹配情况见图 6。

以研究路段的平均速度来衡量道路的交通状态,预测时间间隔为 5 min。首先对原始 GPS 数据进行整理,以获得每 5 min 的道路交通状态。求得在某一时段内经过某一路段的车辆数,以及每辆车通过该路段所需的时间,以此求出每一路段每一时段内的平均车速

$$S_m(t) = L_m / \left(\frac{1}{p_{m,t}} \sum_{r=1}^{p_{m,t}} T_r \right) \quad (3)$$

式中: L_m 为路段 m 的长度; $p_{m,t}$ 为在 t 时段内经过路段 m 的出租车数量; T_r 为第 r 辆出租车通过路段 m 的时间。

表 2 为一辆典型的出租车 GPS 数据,该出租车运行在中华路段 1,由北向南行驶。其进入中华路段 1 的时间为 17:05:11,离开时间为 17:06:01,由此可以计算出该辆出租车在中华路段 1 上的行驶时间为 50 s。同理,可以计算出所有出租车的行驶时间,由此获得各路段不同时段平均运行速度,将速

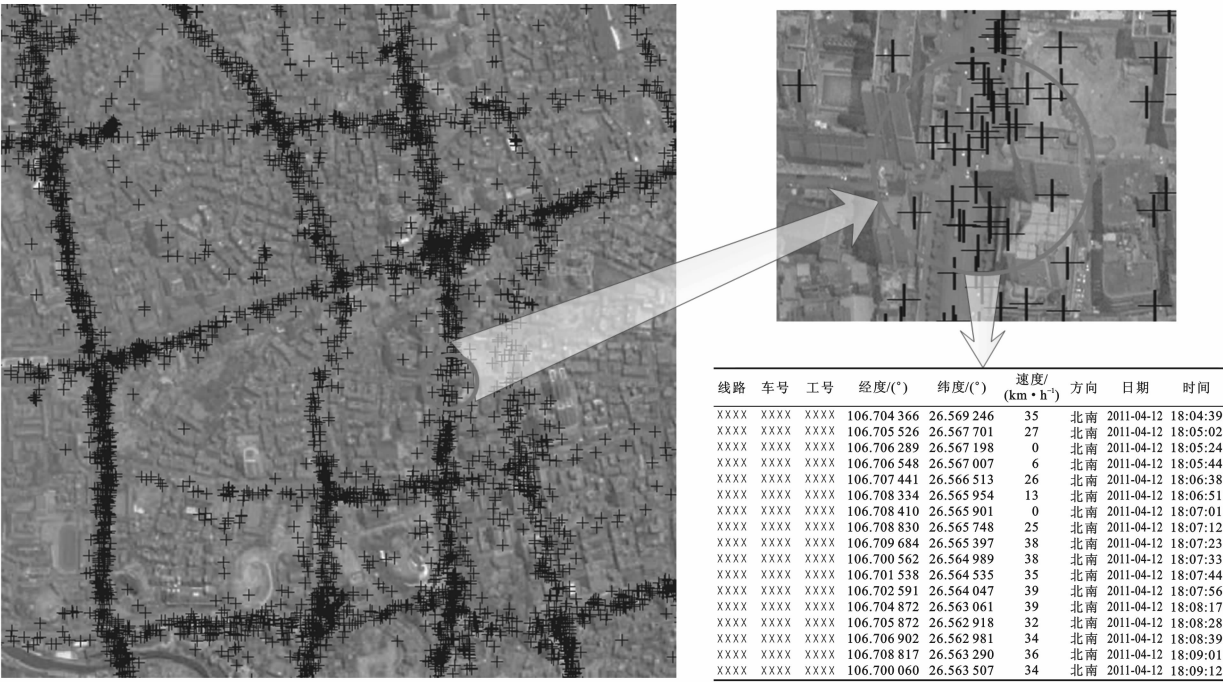


图 6 GPS 系统定位的出租车点

Fig. 6 GPS positioned taxis

表 2 某出租车在中华路段 1 上的 GPS 数据

Fig. 2 GPS data of a certain taxi on Zhonghua Road 1

车号	工号	经度/(°)	纬度/(°)	速度/(km · h ⁻¹)	状态	方向	日期	时间
XXXX	XXXX	106.708 107	26.590 231	17	满载	由北 向南	2011-04-13	17:05:11
		106.708 221	26.589 729	22				17:05:23
		106.708 458	26.589 281	16				17:05:35
		106.708 534	26.589 022	24				17:05:44
		106.708 641	26.588 566	23				17:05:54
		106.708 664	26.588 329	18				17:06:01

度作量纲为 1 处理(下同),结果见图 7。将初始样本数据随机划分为 3 类,分别作为数据库样本、测试样本和预测样本,其中,测试样本和预测样本各占约 20%,其余作为数据库样本(表 2)。

3.2 不同模型的比较

对带有不同状态向量的标准 K 近邻模型(不带权重)进行检验。利用数据库样本和测试样本中的数据,分析前文定义的 4 种模型在 3 个研究路段下一时段交通状态预测过程中的预测效果,结果见图 8。

从图 8 中可以看出,这 4 种模型在 3 个研究路段上的预测效果各不相同。其中,第 1 种模型的预测效果最差,其在 3 个路段上的平均相对误差均为最大,其中,在延安路—省府西路路段的相对预测误差达到最大值,为 39.34%,这说明单纯考虑时间维度的 K 近邻模型,其预测效果明显不如同时考虑时




图 7 三个路段不同时段平均速度

Fig. 7 Average speeds of three road sections during different times

间和空间维度的模型。在 3 种同时考虑时间和空间维度的 K 近邻模型中,第 4 种模型在 3 个路段的预测精度均为最高,3 个路段相对预测误差的平均值




图 8 状态向量对相对预测误差的影响

Fig. 8 Influences of state vectors on relative prediction errors

仅为 7.26%，说明同时考虑到上下游路段交通状态的预测模型要优于单纯考虑上游路段或下游路段的预测模型，即在预测过程中，上游路段和下游路段的交通状况对目标路段交通状况的影响同等重要。预测结果表明，在时间维度的基础上，引入上游路段和下游路段的空间维度参数可以显著提高模型的预测精度。

3.3 不同距离度量方式的比较

为了检验带权重的距离度量方式对模型的改进效果，构建了相关系数权重和指数权重 2 种距离度量方式，利用数据库样本和测试样本中的数据，比较了这 2 种距离度量方式在 3 个研究路段下一时段交通流预测过程中的效果，结果见图 9。




图 9 距离度量方式对相对预测误差的影响

Fig. 9 Influences of distance measure modes on relative prediction errors

从图 9 中可以看出，带权重的距离度量方式在 3 个研究路段中，预测效果均明显优于不带权重的距离度量方式。相比于相关系数权重法，指数权重法的相对预测误差最低，其在 3 个路段上的相对预测误差平均仅为 5.57%，这说明模型中采用带权重的距离度量方式是合理的，可以显著提高 K 近邻模型的预测精度。

3.4 改进后的 K 近邻模型预测效果

为检验基于时空参数的改进后 K 近邻模型的

预测效果，本文将该模型与神经网络模型和历史平均模型进行比较，结果见图 10。




图 10 不同模型的预测结果比较

Fig. 10 Comparison of prediction results of different models

从图 10 可以计算得出，历史平均模型的平均相对误差绝对值 (Mean Absolute Percentage Error, MAPE) 达到 18.64%，神经网络模型的 MAPE 值也超过 13.00%。与这两种模型相比，K 近邻模型的预测精度更高，其 MAPE 值为 9.43%，满足智能交通应用系统对交通流预测的精度要求，说明 K 近邻模型在反映短时交通流复杂的非线性关系上具有一定的优势。另外，在 3 个路段上 K 近邻模型的预测误差均比较稳定，反映出该模型对不同路段均具有良好的适用性。相对而言，神经网络模型和历史平均模型的预测效果都不甚理想，其中历史平均模型的预测效果最差，这主要是因为历史平均模型只考虑目标路段历史数据间的线性关系，忽视了上下游路段对目标路段交通状况的影响，以及目标路段历史数据对预测时段影响程度的差异。

4 结 语

本文选取贵阳市中华路上 3 个路段为研究对象，利用出租车运行的 GPS 数据，构建了 K 近邻短时交通流预测模型，并基于时空参数对模型做了适当改进。通过对改进前后模型预测精度的比较，发现同时考虑时间维度和空间维度的模型，其预测效果要明显优于只考虑时间维度的模型，并且同时考虑上下游路段交通状况的模型，其预测效果稍优于只考虑上游路段或下游路段的模型，这说明上游路段和下游路段对目标路段交通状况的影响程度同等重要。将改进后的 K 近邻模型与神经网络模型和历史平均模型进行比较，发现改进后的 K 近邻模型，其预测精度可以达到 90% 以上，更适合对道路短时交通流进行实时、准确的预测。

参考文献:

References:

- [1] 张晓利,陆化普. 非参数回归方法在短时交通流预测中的应用[J]. 清华大学学报: 自然科学版, 2009, 49(9): 1471-1475.
ZHANG Xiao-li, LU Hua-pu. Non-parametric regression and application for short-term traffic flow forecasting[J]. Journal of Tsinghua University: Science and Technology, 2009, 49(9): 1471-1475. (in Chinese)
- [2] 刘静,关伟. 交通流预测方法综述[J]. 公路交通科技, 2004, 21(3): 82-85.
LIU Jing, GUAN Wei. A summary of traffic flow forecasting methods[J]. Journal of Highway and Transportation Research and Development, 2004, 21(3): 82-85. (in Chinese)
- [3] 朱顺应,王红,李关寿. 路段上短时间区段内交通量预测ARIMA模型[J]. 重庆交通学院学报, 2003, 22(1): 76-77, 95.
ZHU Shun-ying, WANG Hong, LI Guan-shou. The ARIMA model used in forecasting of traffic volume in short interval on the link [J]. Journal of Chongqing Jiaotong University, 2003, 22(1): 76-77, 95. (in Chinese)
- [4] 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.
- [5] 聂佩林,余志,何兆成. 基于约束卡尔曼滤波的短时交通流量组合预测模型[J]. 交通运输工程学报, 2008, 8(5): 86-90.
NIE Pei-lin, YU Zhi, HE Zhao-cheng. Constrained Kalman filter combined predictor for short-term traffic flow[J]. Journal of Traffic and Transportation Engineering, 2008, 8(5): 86-90. (in Chinese)
- [6] 宋国杰,胡程,谢昆青,等. 面向实时短时交通流预测的过程神经网络建模[J]. 交通运输工程学报, 2009, 9(5): 73-77.
SONG Guo-jie, HU Cheng, XIE Kun-qing, et al. Process neural network modeling for real time short-term traffic flow prediction [J]. Journal of Traffic and Transportation Engineering, 2009, 9(5): 73-77. (in Chinese)
- [7] SMITH B L, WILLIAMS B M, OSWALD R K. Comparison of parametric and nonparametric models for traffic flow forecasting[J]. Transportation Research Part C: Emerging Technologies, 2002, 10(4): 303-321.
- [8] HSU C W, LIN C J. A comparison of methods for multi-class support vector machines[J]. IEEE Transactions on Neural Networks, 2002, 13(2): 415-425.
- [9] 徐启华,杨瑞. 支持向量机在交通流量实时预测中的应用[J]. 公路交通科技, 2005, 22(12): 131-134.
XU Qi-hua, YANG Rui. Traffic flow prediction using support vector machine based method[J]. Journal of Highway and Transportation Research and Development, 2005, 22(12): 131-134. (in Chinese)
- [10] 干宏程,汪晴,范炳全. 基于宏观交通流模型的行程时间预测[J]. 上海理工大学学报, 2008, 30(5): 409-413.
GAN Hong-cheng, WANG Qing, FAN Bing-quan. Travel time prediction based on macroscopic traffic flow models[J]. Journal of University of Shanghai for Science and Technology, 2008, 30(5): 409-413. (in Chinese)
- [11] 翁剑成,荣健,任福田,等. 基于非参数回归的快速路行程速度短期预测算法[J]. 公路交通科技, 2007, 24(3): 93-97, 106.
WENG Jian-cheng, RONG Jian, REN Fu-tian, et al. Non-parametric regression model based short-term prediction for expressway travel speed[J]. Journal of Highway and Transportation Research and Development, 2007, 24(3): 93-97, 106. (in Chinese)
- [12] 张晓利,贺国光,陆化普. 基于K-邻域非参数回归短时交通流预测方法[J]. 系统工程学报, 2009, 24(2): 178-183.
ZHANG Xiao-li, HE Guo-guang, LU Hua-pu. Short-term traffic flow forecasting based on K-nearest neighbors non-parametric regression[J]. Journal of Systems Engineering, 2009, 24(2): 178-183. (in Chinese)
- [13] DAVIS G A, NIHAN N L. Nonparametric regression and short-term freeway traffic forecasting[J]. Journal of Transportation Engineering, 1991, 117(2): 178-188.
- [14] 张涛,陈先,谢美萍,等. 基于K近邻非参数回归的短时交通流预测方法[J]. 系统工程理论与实践, 2010, 30(2): 376-384.
ZHANG Tao, CHEN Xian, XIE Mei-ping, et al. K-NN based nonparametric regression method for short-term traffic flow forecasting[J]. Systems Engineering—Theory and Practice, 2010, 30(2): 376-384. (in Chinese)
- [15] SMITH B L, DEMETSKY M J. Traffic flow forecasting: comparison of modeling approaches[J]. Journal of Transportation Engineering, 1997, 123(4): 261-266.
- [16] YU Bin, LAM W H K, TAM M L. Bus arrival time prediction at bus stop with multiple routes [J]. Transportation Research Part C: Emerging Technologies, 2011, 19(6): 1157-1170.