

文章编号:1671-1637(2014)03-0087-08

短时交通流预测的改进 K 近邻算法

谢海红^{1,2}, 戴许昊¹, 齐 远³

(1. 北京交通大学 城市交通复杂系统理论与技术教育部重点实验室, 北京 100044; 2. 北京城市交通协同创新中心, 北京 100044; 3. 湖南省交通规划勘察设计院, 湖南 长沙 410008)

摘 要:分析了原有的短时交通流预测的 K 近邻算法, 用模式距离搜索方法代替原有的欧氏距离搜索方法, 引入多元统计回归模型, 建立了一种改进的短时交通流预测的 K 近邻算法, 并以北京市某路段进行实例验证。试验结果表明: 当 K 取 23 时, 利用改进的 K 近邻算法, 预测结果的均方误差、平均相对误差、平均绝对误差分别为 31.43%、4.17%、0.27%; 利用原有的 K 近邻算法, 预测结果的均方误差、平均相对误差、平均绝对误差分别为 33.33%、4.40%、0.28%; 利用历史平均模型, 预测结果的均方误差、平均相对误差、平均绝对误差分别为 46.20%、11.40%、0.48%。可见, 改进的 K 近邻算法的预测精度明显高于其他 2 种方法, 在提高搜索效率的同时准确地刻画了交通流的真实情况。

关键词: 交通规划; 短时交通流预测; K 近邻算法; 模式距离; 多元统计回归

中图分类号: U491.112

文献标志码: A

Improved K -nearest neighbor algorithm for short-term traffic flow forecasting

XIE Hai-hong^{1,2}, DAI Xu-hao¹, QI Yuan³

(1. MOE Key Laboratory for Urban Transportation Complex Systems Theory and Technology, Beijing Jiaotong University, Beijing 100044, China; 2. Center of Cooperative Innovation for Beijing Metropolitan Transportation, Beijing 100044, China; 3. Hunan Provincial Communications Planning, Survey and Design Institute, Changsha 410008, Hunan, China)

Abstract: The original K -nearest neighbor algorithm for short-term traffic flow forecasting was analyzed. Pattern distance search method was used to replace the original Euclidean distance search method, the multiple statistics regression model was introduced, an improved K -nearest neighbor algorithm for short-term traffic flow forecasting was put forward, and an example verification was carried out by using the traffic flow data from a certain section in Beijing. Test result indicates when K is 23, the error of mean square, mean absolute error and average relative error of forecasting results are 31.43%, 4.17% and 0.27% respectively by using the improved K -nearest neighbor algorithm. By using the original K -nearest neighbor algorithm, the error of mean square, mean absolute error and average relative error of forecasting results are 33.33%, 4.40% and 0.28% respectively. By using the historical average model, the error of mean square, mean absolute error and average relative error of forecasting results are 46.20%, 11.40% and 0.48% respectively. The forecasting accuracy of the improved K -nearest neighbor algorithm is obviously higher than the other two algorithms. The improved K -nearest neighbor algorithm not

收稿日期: 2014-01-13

基金项目: 国家 973 计划项目(2012CB725403)

作者简介: 谢海红(1963-), 女, 山东烟台人, 北京交通大学副教授, 从事城市交通规划与管理研究。

only increases searching efficiency, but also accurately reflects the real situation of traffic flow.
2 tabs, 11 figs, 22 refs.

Key words: traffic planning; short-term traffic flow forecasting; K-nearest neighbor algorithm; pattern distance; multiple statistical regression

Author resume: XIE Hai-hong(1963-), female, associate professor, +86-10-51687138, xiehaihong16@163.com.

0 引 言

智能交通系统(ITS)已经在世界范围内广泛应用,成为城市交通控制的有力工具。ITS的主要基础理论是确定交通流的主要参数与交通事件的预测算法。交通控制和交通诱导系统都需要在做出控制(诱导)变量决策的时刻对下一决策时刻乃至以后若干时刻的交通流量做出短期实时预测。一般认为,预测时间跨度不超过 15 min(甚至小于 5 min)的预测是短时交通预测^[1],因此,实时、准确地预测交通流是实现交通控制和交通诱导的关键。

众多学者将数学物理方法用于交通流的动态预测研究。常用的方法主要分为 3 类:解析数学方法,包括历史均值法^[2-3]、回归预测法^[2]、时间序列法^[4]、卡尔曼滤波法^[5-6]等;智能预测方法,包括非参数回归预测方法、神经网络预测法^[7]、混沌理论^[8]、分形理论^[9]等;此外还有组合预测模型^[10-12]方法。历史均值法、回归预测法相对经典,Williams 等全面而系统地阐述了季节性 ARIMA 模型在交通流预测的理论基础^[4];Okutani 等利用卡尔曼滤波理论建立了交通流预测模型^[5]。虽然这 2 种方法精度较高,实时性较强,但其参数训练非常复杂。在之后的研究中,大部分学者结合不同方法的优点对原有单一方法进行了改进。董春娇等采用 Elman 神经网络模型实现了道路网多断面交通流短时预测,弥补了原有神经网络模型的缺陷^[7];魏文等针对交通流的非线性和不确定性,将混沌理论与 PSO 神经网络相结合,同样取得了精良的预测效果^[8];樊娜等结合 BP 神经网络与非参数回归模型,在短时交通流预测的方法上创新性地提供了新的思路^[10]。近年来多种组合预测模型方法^[11-12]被有机结合于交通流的预测研究中,实现了城市道路上下游交通流的短时预测。智能预测方法相对于其他方法的优势在于不需要太复杂的数学经验模型,只需要具备充足的历史数据便可阐释交通流的动态变化规律^[13-16]。

非参数回归预测是智能预测方法中具有较好数据挖掘和移植性能的方法^[16],K 近邻算法是非参数

回归中相对常用的方法。Smith 等很早将 K 近邻非参数回归用于交通流预测,并针对模型的特点做了多项成功的改进措施^[13];宫晓燕等最早系统地将 K 近邻算法用于短时交通流的预测,通过提出基于聚类分析的事件检测算法使得 K 近邻算法成为一种可移植的实时算法^[14];周小鹏等针对交通流量变化存在周期性和随机性的特点,提出将近邻的个数不设为常量而取决于所能搜索到的记录数,并采用等权重法进行预测^[15];于滨等通过引入时空参数与指数权重,改变以往平面化状态的设置,并从另外 1 个角度考虑改进 K 近邻模型^[16];屈莉等通过浮动车系统进行数据采集,并引入反馈机制,增强了 K 近邻短时交通流预测算法的准确性^[17-18]。以上研究大多在状态的构造和数据的组织形式上有所创新,但在以下 2 方面还仍有不足:在实时数据与样本数据匹配搜索过程中,大体上还是以基于欧氏距离搜索的机制为主,欧氏距离需要对数据进行多次平方、开方的运算,计算繁琐;在预测方法上,大多还是由当前状态来直接预测下一时刻的状态,忽略了其他因素对所预测状态的影响。针对以上 2 点不足,本文分别对原有 K 近邻算法作了以下改进:在搜索机制上拟引入时间序列的模式距离^[19],在不影响预测精度的前提下提高搜索效率;在预测方法上结合多元统计回归的特点改进原有 K 近邻算法,以期进一步提高预测精度。另外,随着 RTMS 在交通流实时监测的广泛应用,RTMS 连续监测的数据可以作为本文原始数据的来源。本文基于北京市某相关路段 RTMS 的检测数据,对改进的 K 近邻算法做了验证,以为后续研究提供新的思路。

1 算法设计

1.1 K 近邻算法

K 近邻算法是非参数回归方法中较常用的一种算法^[18],构建 K 近邻短时交通流预测模型的算法流程如下:首先,构建具有较大容量且有代表性的历史数据库;其次,通过选取与预测对象最为相关的因素确定状态,一般有道路流量、占有率、地点车速

等;第三,确定近邻个数 K 的取值以及距离的搜索方式作为算法的搜索机制;最后,确定下一时刻状态的预测方法。

在预测算法中,最常用的是基于欧氏距离的搜索方法

$$d_{Ei} = \sqrt{\sum_j \eta_j (x_{tj} - x_{tLij})^2} \quad (1)$$

$$x_{t+1} = \sum_{i=1}^K \alpha_i x_{(t+1)Li} \quad (2)$$

$$\alpha_i = \frac{d_{Ei}^{-1}}{\sum_{i=1}^K d_{Ei}^{-1}} \quad (3)$$

式中: d_{Ei} 为第 i ($i=1,2,\dots,K$) 组近邻状态与当前时刻 t 状态的欧氏距离; η_j 为当前数据中第 j 个子项的权重; x_{tj} 为当前 t 时刻第 j 个子项的状态; x_{tLij} 为当前时刻 t 第 i 组历史数据近邻中第 j 个子项的状态; x_{t+1} 为 $t+1$ 时刻的状态; $x_{(t+1)Li}$ 为 $t+1$ 时刻第 i 组近邻的状态; α_i 为第 i 组近邻状态的权重。

1.2 模式距离搜索方法

根据状态时间序列的变化趋势,在历史数据中按其接近的变化趋势划分等长的状态时间序列片段 S ,即代表一种模式^[19],可表示为

$$S = \{s_1, s_2, \dots, s_\varphi, \dots, s_n\} \quad (4)$$

$$s_\varphi = (r_\varphi, x_\varphi) \quad (5)$$

式中: s_φ 为第 φ ($\varphi=1,2,\dots,n$) 个子模式; x_φ 为第 φ 个子模式中的状态; r_φ 为第 φ 个子模式中的变化趋势。

模式距离计算方法为

$$d_M = \frac{1}{n} \sum_{\varphi=1}^n d_{M\varphi} + 100I \quad (6)$$

$$d_{M\varphi} = |r_{1\varphi} - r_{2\varphi}| \quad (7)$$

式中: d_M 为模式距离; $d_{M\varphi}$ 为第 φ 组子模式间的距离; $r_{1\varphi}$ 、 $r_{2\varphi}$ 分别为 2 种模式下第 φ 组子模式对应的变化趋势; I 为随机变量。

模式距离搜索方法的流程图见图 1,求解步骤如下。

Step 1: 确定预测对象的状态 x_t 。

Step 2: 定义平均相对误差 ξ ,对预测对象的状态 x_t 的近邻个数 K 分别尝试选取足够的正整数值。根据 K 的尝试值并结合式(8)计算 ξ 值。作二维图像, ξ 最低点所对应的横坐标即为要选取的 K 值

$$\xi = \frac{100}{n} \sum_{\mu=1}^n \frac{|\hat{x}_{(t+1)\mu} - x_{t\mu}|}{x_{t\mu}} \quad (8)$$

式中: $x_{t\mu}$ 为 t 时刻第 μ 个被预测的状态; $\hat{x}_{(t+1)\mu}$ 为 $t+1$ 时刻第 μ 个被预测状态的估计值。

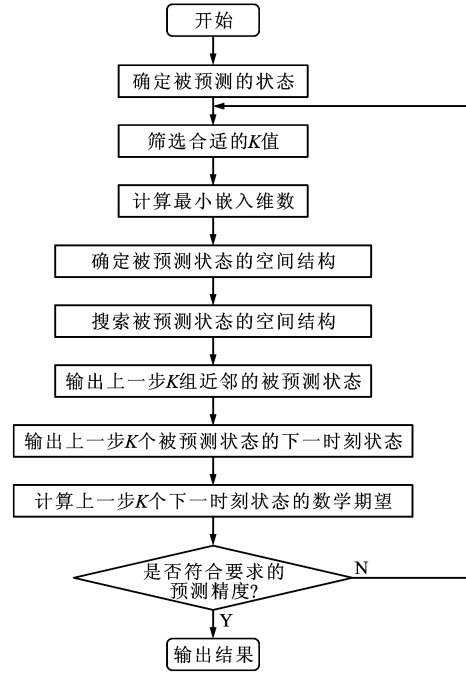


图1 算法流程

Fig. 1 Algorithm flow

Step 3: 确定状态的最小嵌入维数。设历史数据库中样本状态组成时间序列,经时延技术处理以后获得 l 组向量 y_k ($k=1,2,\dots,l$),由 Cao 算法理论可知^[20-21]

$$T_m = \frac{E_{m+1}}{E_m} \quad (9)$$

$$l = N - (m - 1)\tau$$

$$E_m = \frac{1}{N - m\tau} \sum_{k=1}^{N-m\tau} \theta_{m,k} \quad (10)$$

$$\theta_{m,k} = \frac{\|y_{(m+1)k} - y_{(m+1)Lk}\|_2}{\|y_{mk} - y_{mLk}\|_2} \quad (11)$$

$$y_k = (x(t_k), x(t_k + \tau), \dots, x(t_k + (m-1)\tau)) \quad (12)$$

式中: m 为嵌入维数; E_m 为 m 维嵌入维度分析式; T_m 为 E_m 与 E_{m+1} 嵌入维数分析式的比值; $\theta_{m,k}$ 为 Cao 算法中定义的第 k 组 m 维空间向量的阈值系数; y_{mk} 为经时延技术处理后第 k 组 m 维空间向量; y_{mLk} 为 y_{mk} 的 m 维最近邻空间向量; τ 为延滞时间; N 为时间序列状态数量。

当取到某一个整数 m_0 之后的整数时,比值 T_m 保持不变或变化较小,此时最小嵌入维数为 $m_0 + 1$,输出 m_0 。

Step 4: 由 Step 3 输出的最小嵌入维数 m_0 确定被预测状态 x_t 的空间结构向量

$$X_t = (x_t, x_{t-1}, \dots, x_{t-m_0}) \quad (13)$$

Step 5: 按照式(6)、(7)所确定的模式距离搜索

方法在历史数据库中搜索当前被预测状态空间结构向量 \mathbf{X}_i 的 K 组近邻向量 \mathbf{X}_{iL1} , 并输出 K 组近邻向量 $\mathbf{X}_{iL1}, \mathbf{X}_{iL2}, \dots, \mathbf{X}_{iLK}$ 。

Step 6: 输出近邻向量 $\mathbf{X}_{iL1}, \mathbf{X}_{iL2}, \dots, \mathbf{X}_{iLK}$ 中的被预测状态 x_{iLi} 。

Step 7: 在历史数据库中搜索 x_{iLi} 的下一时刻状态 $x_{(t+1)Li}$, 计算并输出其数学期望 $\bar{x}_{(t+1)L}$, 为所预测的下一时刻状态, 即

$$x_{t+1} = \bar{x}_{(t+1)L} \quad (14)$$

1.3 基于多元统计回归的改进算法

延续为 K 近邻寻找最优权重的思路, 原有的 K 近邻算法下一时刻的状态与近邻状态下一时刻状态之间存在着显著的局部线性关系。多元统计回归模型正好也具有这种局部线性特点。此外, 多元统计回归模型中的误差项作为无限逼近实际值的附加因子而带有不确定性。这种带有不确定性的误差项正好能弥补原有 K 近邻算法对于无法观测到未知因素概括的不足, 可以较真实地还原短时交通流的不确定性和非线性, 因此, 本文在 K 近邻算法的基础上结合多元统计回归的特点提出改进预测算法。基于多元统计回归的改进算法流程图见图 2。

基于多元统计回归的改进算法为

$$x_{t+1} = \mathbf{Y}\boldsymbol{\beta} + \epsilon \quad (15)$$

$$\mathbf{Y} = (1, x_{(t+1)L1}, x_{(t+1)L2}, \dots, x_{(t+1)LK}) \quad (16)$$

$$\boldsymbol{\beta} = (\beta_0, \beta_1, \dots, \beta_K)^T$$

式中: $\boldsymbol{\beta}$ 为不同近邻下各状态的回归参数; ϵ 为随机误差项。

2 计算结果分析

2.1 数据来源与处理

本文选取北京市海淀区高梁桥斜街至大柳树路段由南向北方向共 5 个车道的交通流量为研究对象。路段全长 1.5 km, 双向 10 车道, 共 3 个交叉口 (其中与大慧寺路交叉口为丁字交叉口), 隔离条件较好。实测现场见图 3。

文献[15]将决定交通流的不同因素做了相关性研究, 分析结果表明, 在一定范围内, 交通量与速度之间相关性较低, 道路占有率与交通量的变化趋势大致相同。本文着重于对预测算法进行改进, 因此, 只考虑将交通量作为状态因素, 并尽可能降维。

RTMS 在交通流量方面具有很高的检测精度^[22], 通过 RTMS 交通检测器与终端串口服务器相连, 采集现场交通数据。检测器原始数据采集的

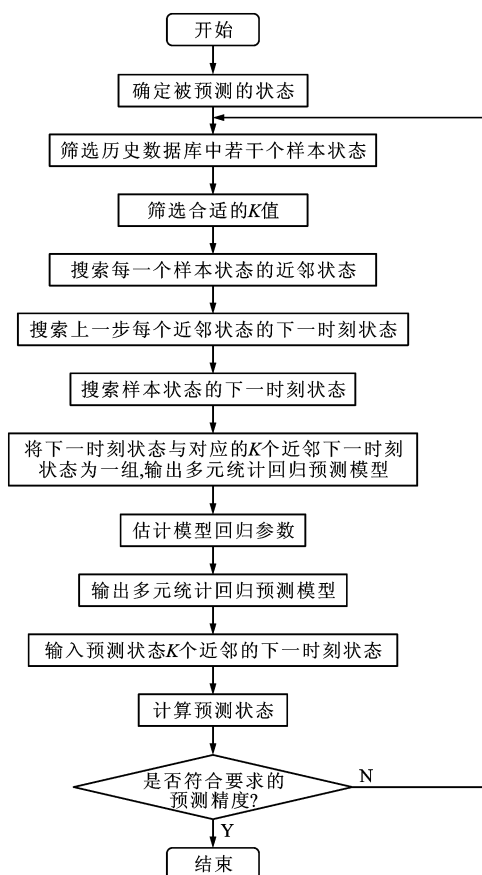


图 2 多元统计回归算法流程

Fig. 2 Flow of multiple statistical regression algorithm




图 3 实测现场

Fig. 3 Measurement field

时间间隔为 30 s, 采集内容依次为采集时间、车道号、交通量、平均速度、道路占有率、大车交通量。通过对 2013 年 3、4、5 三个月份的数据进行比对筛选, 发现 2013 年 4 月份获取的数据相对比较完整, 选取 2013 年 4 月 8 日至 2013 年 4 月 29 日共 22 d 的全天连续交通流量数据为样本。以 1 min 为预测时间间隔, 通过对 22 d 的数据进行处理, 获得有效样本容量为 30 240 的连续交通流量数据。样本数据较好显示出了该路段交通流量的周期性, 见图 4, 横坐标 1~8 分别为 4 月 15 日至 4 月 22 日每天 0:00 时刻。为了较较好地进行检测, 将初始样本随机划分为

3类进行算法检测^[17],分别作为历史数据库样本、测试样本和预测样本,其中测试样本和预测样本各占15%,其余作为历史数据库样本。





图4 交通量

Fig. 4 Traffic volumes

2.2 K值的确定

将获得的交通流量历史数据库样本结合式(8)计算得到K值。从图5中可以看出不同K近邻预测下对应的平均相对误差呈现明显的波动情况,并不是某一种增减的单调关系,K值过大或过小都会影响预测的精度, ξ 值越小,整体预测效果与实际观测值就越接近。图5中,K取22~24范围内可获得相对较高的精度,因此,本文分别选取K为22、23、24对样本集进行预测。


图5 ξ 与K关系Fig. 5 Relationship between ξ and K

2.3 模式距离与欧氏距离搜索结果比较

本文以1 min为间隔, m 取1~50的整数,分别得到相应的比值 T_m 见图6,从中可以看出,当 $m>10$ 时, T_m 维持在1.0的附近不再变动。以11个连续时点交通量构成的状态已经能较好地刻画出交通流的空间结构,选取的状态空间结构为

$$\mathbf{X}_t = (x_t, x_{t-1}, \dots, x_{t-9}, x_{t-10}) \quad (17)$$

为了展示基于模式距离搜索算法的验证效果,以1 min为时间间隔,在多组测试结果中随机抽取一组状态(4月16日上午9:56至10:06 11个时刻

图6 T_m 曲线Fig. 6 T_m curve

的交通量)作为预测状态空间结构向量,分别利用模式距离和欧氏距离2种不同的搜索方法进行计算。在历史数据库中随机选取3组和预测状态进行匹配,计算结果见表1和图7、8。图7中,图7(a)为11个时刻的交通量(原始交通量),图7(b)、(c)、(d)分别为与图7(a)相似的任意3组历史数据库中的时间序列,用 K_1 、 K_2 、 K_3 表示,图8与图7类似,对应的时间序列用 F_1 、 F_2 、 F_3 表示。由图7、8可以看出,与欧氏距离搜索方法比较,模式距离的近邻向量与匹配目标向量的变化趋势也同样保持了较高的同向性,虽然通过模式距离搜索方法获得的结果较欧氏距离搜索方法稍有损失,但模式距离搜索方法也将其控制在了相对较小范围内。这说明基于模式距离的搜索方法不仅节约了搜索时间,而且搜索所得到的近邻匹配度与欧氏距离搜索下的近邻匹配度相比没有损失太多。可见,基于模式距离的搜索改进是有价值的,因此,在实时在线预测中结合需要可以损失一部分的近邻匹配度来节约更多的搜索时间。由表1可以看出,模式距离搜索结果简便,可减少数据库的扫描次数,因此,当数据库容量过大,系统运算效率又有较高要求时,可以考虑利用模式距离搜索方法。

表1 欧氏距离与模式距离搜索结果

Tab. 1 Search results with Euclidean distance and pattern distance

方法	获取的3组K近邻	所对应计算距离	下一时刻观测值/(veh · min ⁻¹)
欧氏距离搜索	K_1	14.628 7	19
	K_2	12.649 1	40
	K_3	10.770 3	31
模式距离搜索	F_1	0.2	42
	F_2	0.2	33
	F_3	0.0	39

2.4 改进算法的预测精度分析

将均方误差 δ 、平均绝对误差 λ 、平均相对误差 ξ

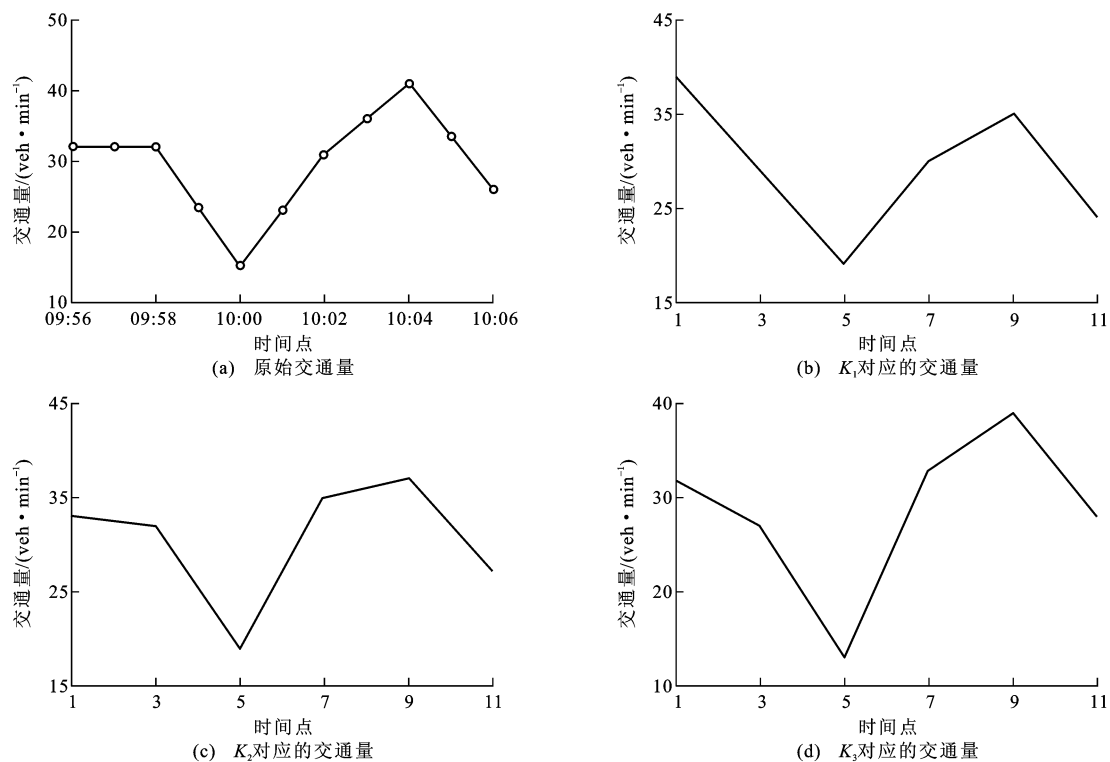


图 7 欧氏距离搜索结果

Fig. 7 Search result by using Euclidean distance

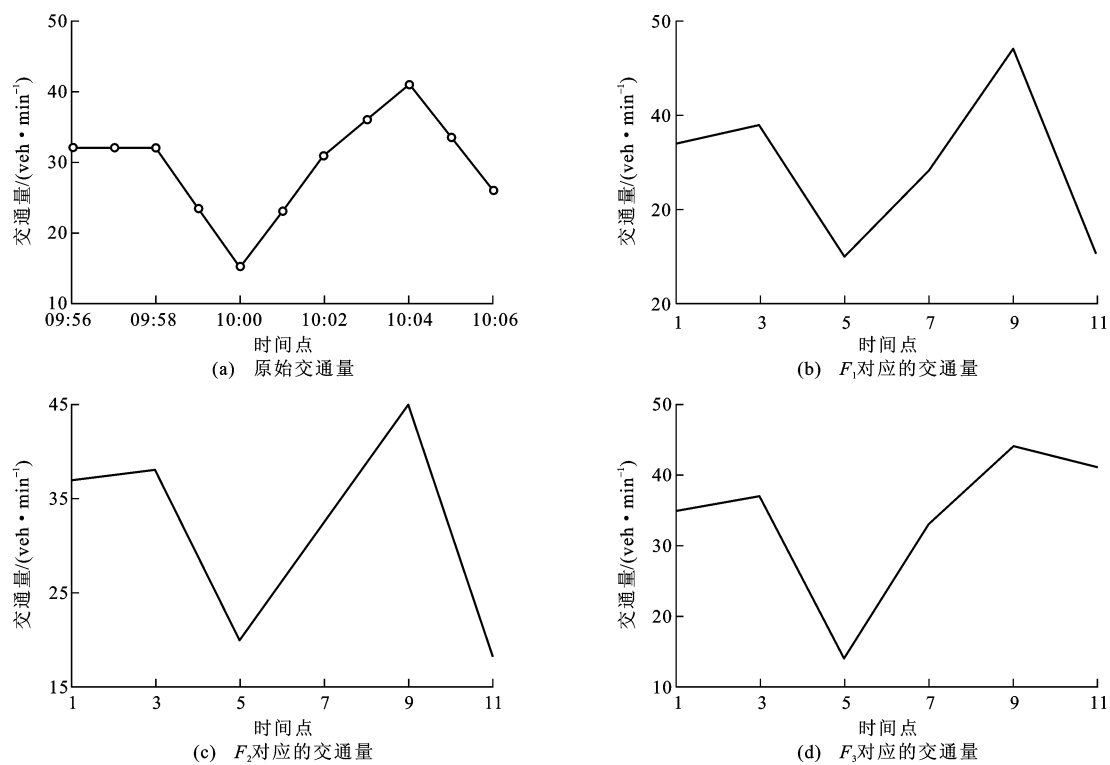


图 8 模式距离搜索结果

Fig. 8 Search result by using pattern distance

三种指标作为预测算法的误差属性对结果进行全面评价。将本文算法、原有 K 近邻算法和历史平均模型 3 种方法的预测结果进行比较,分别见图 9~11。

由于各个误差指标的观察角度不一样,对相应预测模型的精度描述也存在差异,并且指标之间的相关性极强,对模型误差的解释能力难分高低,因




图9 均方误差

Fig. 9 Errors of mean square




图10 平均绝对误差

Fig. 10 Mean absolute errors




图11 平均相对误差

Fig. 11 Average relative errors

此,很难用其中的若干项指标直接断定预测模型的好坏。鉴于这方面考虑,本文将采用因子分析方法对数据进行降维处理,并根据最后的因子得分作为最终标准评价各个模型的预测精度。通过统计软件将误差结果标准化以后的因子得分排序见表2,误差因子绝对值得分越小,相应的模型预测精度越高。从表2可以看到本文提出的改进算法因子得分为-0.224 1,预测效果较理想,因此,在以提高精度为目的的动态短时交通流预测时,本文提出的改进算法具有明显的优势。

表2 因子排序结果

Tab. 2 Factor order result

方法	本文算法	原有K近邻算法	历史平均模型 (参考基准)
因子得分	-0.224 1	0.438 9	2.136 0

3 结 语

本文在原有的短时交通流预测K近邻算法上分别做了2方面的改进:引入了模式距离搜索方法替换以往单纯的欧氏距离搜索方法,不仅提供了考察交通流的物理角度,而且在尽量不影响精度的前提下提高了K近邻的搜索速率,降低了单点短时交通流预测的搜索成本;结合多元统计回归的优点,引入多元统计回归参数估计方法对原有K近邻算法进行改进。通过实例检验,改进算法的误差因子绝对值得分最小,表明其在短时交通流动态预测中具有突出的优势,能较准确地预测动态交通流变化信息。

虽然模式距离搜索方法提供了短时交通流预测的物理角度,但是只考虑了向量的起伏状态,且没有携带如交通流变化缓急程度等具体的起伏信息,因此,可以从更具物理意义多维距离上细化预测算法,以希望能携带更多路况信息。另外,基于多元统计回归的改进算法还不具备长期稳定性,需要不定期更新回归数据样本,筛选异常值,但这样会有很大的计算工作量。今后可以结合研发快速更新样本数据的算法,从更准确快速的角度进一步改进短时交通流的预测工作。

参考文献:

References:

- [1] 贺国光,李宇,马寿峰. 基于数学模型的短时交通流预测方法探讨[J]. 系统工程理论与实践, 2000, 20(12): 51-56.
HE Guo-guang, LI Yu, MA Shou-feng. Discussion on short-term traffic flow forecasting methods based on mathematical models [J]. Systems Engineering—Theory and Practice, 2000, 20(12): 51-56. (in Chinese)
- [2] SMITH B L, DEMETSKY M J. Traffic flow forecasting: comparison of modeling approaches[J]. Journal of Transportation Engineering, 1997, 123(4): 261-266.
- [3] KREER J B. A comparison of predictor algorithms for computerized control[J]. Traffic Engineering, 1975, 45(4): 51-56.
- [4] 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, 2003, 129(6): 664-672.

- [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] SIMON D, SIMON D L. Kalman filtering with inequality constraints for turbofan engine health estimation[J]. Control Theory and Applications, 2006, 153(3): 371-378.
- [7] 董春娇,邵春福,熊志华,等.基于 Elman 神经网络的道路网短时交通流预测方法[J].交通运输系统工程与信息,2010,10(1):145-151.
DONG Chun-jiao, SHAO Chun-fu, XIONG Zhi-hua, et al. Short-term traffic flow forecasting of road network based on Elman neural net work[J]. Journal of Transportation Systems Engineering and Information Technology, 2010, 10(1): 145-151. (in Chinese)
- [8] 魏文,余立建,龚炯.基于混沌理论和 PSO 神经网络的短时交通流预测[J].物流工程与管理,2010,32(2):75-77.
WEI Wen, YU Li-jian, GONG Jiong. Short-time traffic flow prediction based on chaos and particle swarm optimized neural network[J]. Logistics Engineering and Management, 2010, 32(2): 75-77. (in Chinese)
- [9] 承向军,刘军,马敏书.基于分形理论的短时交通流预测算法[J].交通运输系统工程与信息,2010,10(4):106-110.
CHENG Xiang-jun, LIU Jun, MA Min-shu. Algorithm of short-term traffic flow forecasting using fractal theory[J]. Journal of Transportation System Engineering and Information Technology, 2010, 10(4): 106-110. (in Chinese)
- [10] 樊娜,赵祥模,戴明,等.短时交通流预测模型[J].交通运输工程学报,2012,12(4):114-119.
FAN Na, ZHAO Xiang-mo, DAI Ming, et al. Short-term traffic flow prediction model[J]. Journal of Traffic and Transportation Engineering, 2012, 12(4): 114-119. (in Chinese)
- [11] 林德花,袁振洲.基于 IOWA 算子的短时交通流预测方法研究[J].科学技术与工程,2013,13(25):7596-7600.
LIN De-hua, YUAN Zhen-zhou. Research on short-term traffic flow forecasting method based on IOWA operator[J]. Science Technology and Engineering, 2013, 13(25): 7596-7600. (in Chinese)
- [12] ISHAK S, ALECSANDRU C. Optimizing traffic prediction performance of neural networks under various topological input and traffic condition setting[J]. Journal of Transportation Engineering, 2004, 130(7): 452-465.
- [13] SMITH B L, WILLIAMS B M R, OSWALD K. Comparison of parametric and nonparametric models for traffic flow forecasting[J]. Transportation Research Part C: Emerging Technologies, 2002, 10(4): 303-321.
- [14] 宫晓燕,汤淑明.基于非参数回归的短时交通流预测与事件检测综合算法[J].中国公路学报,2003,16(1):82-86.
GONG Xiao-yan, TANG Shu-ming. Integrated traffic flow forecasting and traffic incident detection algorithm based on non-parametric regression[J]. China Journal of Highway and Transport, 2003, 16(1): 82-86. (in Chinese)
- [15] 周小鹏,冯奇,孙立军.基于最近邻法的短时交通流预测[J].同济大学学报:自然科学版,2006,34(10):1494-1498.
ZHOU Xiao-peng, FENG Qi, SUN Li-jun. Short-term traffic flow forecasting based on nearest neighbor algorithm[J]. Journal of Tongji University: Natural Science, 2006, 34(10): 1494-1498. (in Chinese)
- [16] 于滨,邬珊华,王明华,等.K近邻短时交通流预测模型[J].交通运输工程学报,2012,12(2):105-111.
YU Bin, WU Shan-hua, WANG Ming-hua, et al. K-nearest neighbor model of short-term traffic flow forecast[J]. Journal of Traffic and Transportation Engineering, 2012, 12(2): 105-111. (in Chinese)
- [17] 屈莉,兰时勇,张建伟.基于浮动车数据非参数回归短时交通速度预测[J].计算机工程与设计,2013,34(9):3298-3332.
QU Li, LAN Shi-yong, ZHANG Jian-wei. Short-term traffic forecasting based on nonparametric regression and floating car data[J]. Computer Engineering and Design, 2013, 34(9): 3298-3332. (in Chinese)
- [18] 李振龙,张利国,钱海峰.基于非参数回归的短时交通流预测研究综述[J].交通运输工程与信息学报,2008,6(4):34-39.
LI Zhen-long, ZHANG Li-guo, QIAN Hai-feng. Review of the short-term traffic flow forecasting based on the non-parametric regression[J]. Journal of Transportation Engineering and Information, 2008, 6(4): 34-39. (in Chinese)
- [19] 王达,荣冈.时间序列的模式距离[J].浙江大学学报:工学版,2004,38(7):795-798.
WANG Da, RONG Gang. Pattern distance of time series[J]. Journal of Zhejiang University: Engineering Science, 2004, 38(7): 795-798. (in Chinese)
- [20] 吴耿锋,周佩玲,储阅春,等.基于相空间重构的预测方法及其在天气预报中的应用[J].自然杂志,1999,21(2):107-110.
WU Geng-feng, ZHOU Pei-ling, CHU Yue-chun, et al. Prediction based on phrase construction and its application in weather forecast[J]. Nature Magazine, 1999, 21(2): 107-110. (in Chinese)
- [21] 朱莉,吴建华,胡广书.基于Cao算法的心率变异信号分析[J].航天医学与医学工程,2009,22(2):132-134.
ZHU Li, WU Jian-hua, HU Guang-shu. Analysis of heart rate variability signal based on Cao algorithm[J]. Space Medicine and Medical Engineering, 2009, 22(2): 132-134. (in Chinese)
- [22] 陈德望,高海军,陈龙,等.城市高速道路微波检测器 RTMS 的检测精度分析[J].公路交通科技,2002,19(5):122-124.
CHEN De-wang, GAO Hai-jun, CHEN Long, et al. Accuracy analysis of RTMS on urban freeway[J]. Journal of Highway and Transportation Research and Development, 2002, 19(5): 122-124. (in Chinese)