

# 视频检测技术的交通时间预测实证研究<sup>①</sup>

叶 枫, 张丽平

(浙江工业大学 经贸管理学院, 杭州 310023)

**摘 要:** 为了实现利用视频车辆检测器数据计算和预测路段行程时间, 将排队长度数据应用到路段行程时间的计算中, 采用改进粒子群的 BP 神经网络算法和时间序列分析对路段进行实证研究. 将排队长度加入计算得到的决定系数为 93.36%, 比只有流量数据的 BP 神经网络算法改善了 41.03%, 比 BPR(bureau of public roads)路阻函数算法改善了 23.37%. 利用实时的路段行程时间对后续行程时间预测通过时间序列分析得到相对误差为 0.06, 预测下个时段和下一个周期的路段行程时间平均相对误差分别为 0.14、0.15. 结果表明排队长度对于路段行程时间的计算具有较高的准确性, 可以用于城市道路交通时间的预测, 并能有效为智能交通算法的其他指数计算提供思路, 为改善交通状况提供决策支持.

**关键词:** 视频车辆检测器; 粒子群算法; BP 神经网络; 时间序列; 排队长度; 行程时间

## Empirical Study on Travel Time Prediction with Video Detection Technology

YE Feng, ZHANG Li-Ping

(College of Business Administration, Zhejiang University of Technology, Hangzhou 310023, China)

**Abstract:** In order to calculate and estimate travel time with the data of video vehicle detectors, data of queue length is applied to the calculation of travel time and the roads are researched with the improved BP neural network algorithm and time series analysis. The decision coefficient is 93.36% when queue length is added to the calculation, which is improved by 41.03% compared with the neural network algorithm for the traffic data only, and 23.37% compared with the BPR algorithm. Using real-time travel time can be used to predict the follow-up travel time. And through the time series analysis, the relative error is 0.06. The average relative errors are 0.14 and 0.15 respectively for forecasting the travel time of the next period and next cycle. Results show that the queue length has higher accuracy for calculating travel time, which can be used to predict travel time of the urban road. The algorithm can provide ideas for calculation of index for other algorithms in the field of intelligent transportation and can also provide decision support for improving the traffic situation.

**Key words:** video vehicle detector; particle swarm optimization; BP neural network algorithm; time series; queue length; travel time

城市交通的快速发展使得交通需求的迅速增长, 同时面临交通运行的巨大压力和挑战, 智能交通系统成了很多城市研究的重要内容. 智能交通的研究包括交通拥堵、交通事故、行程时间、车辆调度等方面, 而行程时间的计算是这些研究中需要考虑的因素, 提高交通时间计算结果的准确度, 能为智能交通其他算法的研究提供基础保障.

在基于固定检测器计算交通时间的方法中, 流量函数模型研究与应用最为广泛, 自由流时间、流量和通

行能力是最常用的自变量, 如 BPR 模型<sup>[1]</sup>、基于流量守恒法的模型<sup>[2]</sup>等. BPR 模型是 1964 年美国联邦公路局提出, 是影响最大且应用最广泛的路段行程时间估计模型, 经过国内学者的改进得出路段速度估计模型<sup>[3,4]</sup>. 原始的 BPR 模型适用于公路, 城市道路中受交通信号控制等设施的影响, 流量增加产生的交通时间延误只占总延误的一部分, 直接运用上述流量函数模型估计交通时间的效果不够理想.

在视频检测技术基础上, 本文在流量函数模型的

<sup>①</sup> 收稿时间:2016-09-25;收到修改稿时间:2016-11-07 [doi: 10.15888/j.cnki.csa.005803]

局限中引入排队长度数据,排队长度<sup>[5]</sup>是指在交通间断点处排队车辆占有的路段长度,排队长度可以用来衡量交通拥堵状况,用于城市道路交通时间的计算是合理的.排队长度的数据来源于路口视频检测器的检测,同时还包括车辆速度、流量等,由于视频车辆检测器中的速度是车辆的瞬时速度,直接用于路段行程时间的计算得到的效果并不好,因此建立视频检测数据各变量尤其是排队长度与路段行程时间之间的关系,是本文的突破点.

## 1 算法模型

### 1.1 模型步骤

本文分为两个部分,第一部分利用视频检测技术完成路段行程时间的计算,第二部分使用结果进行预测.基于视频检测技术的路段行程时间计算是通过检测器的各种数据得出经过路段所需要的时间,这有利于计算路段的平均速度,从而判断道路的拥堵情况.在预测过程中,由于路段行程时间既有周期性,又有变化性,因此需要用到交通时间历史数据和实时数据.在计算过程中用到的算法为改进的BP神经网络算法,预测则使用时间序列分析方法.具体流程如图1.

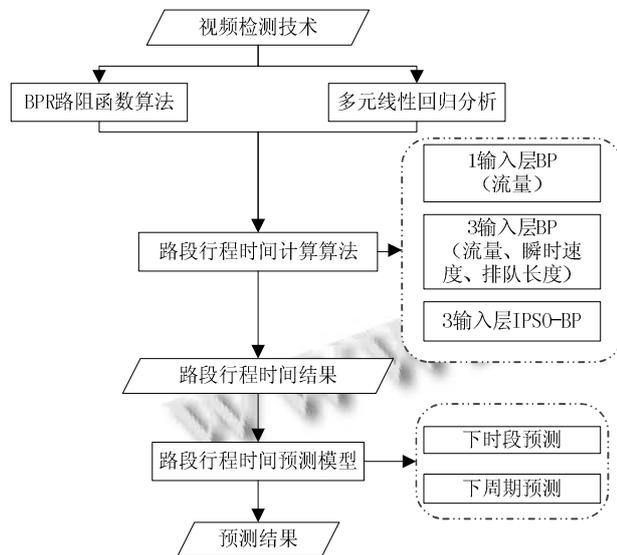


图1 模型流程图

为了验证排队长度对交通时间的影响效果显著,首先通多单因素方差分析方法发现瞬时速度、统计流量、排队长度的  $\text{sig} < 0.05$ , 然后通过多元回归分析判断排队长度与车道流量对路段行程时间的影响显著性,

将具有显著影响的多个变量运用改进粒子群的BP神经网络算法验算,对比排队长度的加入对算法结果的改进效果,并与现有模型BPR路阻函数对比,发现预测性能明显提高,分析BPR路阻函数的缺陷.为了掌握未来周期内的交通时间,同时考虑到交通时间的周期性和变化性,利用历史和实时的路段行程时间对后续行程时间预测(分别预测下个时段和下个周期),采用时间序列分析得出结果并与实际值比较得到最优的关系函数.

### 1.2 使用算法

#### 1.2.1 基于BPR路阻函数算法

BPR模型采用自由流时的行程时间、流量与通行能力比值建立回归模型<sup>[1]</sup>,其公式为:

$$t_b = t_f \left[ 1 + a \left( \frac{q}{c} \right)^b \right] \quad (1)$$

在自由通行时间 $t_f$ 和道路的最大通行能力 $c$ 给定的情况下,根据有效的时间和流量数据拟合出最优的 $\alpha$ 和 $\beta$ 值,因此部分路段时间没算出来而有路段流量的数据可以用此函数来计算路段的时间.当数据量充足时,模型简单易于标定.

#### 1.2.2 IPSO-BP算法

BP神经网络具有很强的非线性映射能力<sup>[1]</sup>,在数据复杂情况下,比传统的统计方法计算准确性高,利用传统的多元线性回归模型的一般形式为:

$$t_q = \beta_0 + \beta_1 / v_s + \beta_2 q + \beta_3 m \quad (2)$$

其中 $v_s$ 表示视频检测中的瞬时速度, $q$ 表示视频检测中的流量, $m$ 表示视频检测中的排队长度, $t_q$ 是此方法拟合时间.

在使用BP神经网络训练交通时间过程中,会出现误差收敛速度慢,学习时间长,容易陷入局部最小等缺点,因此沈学利等使用IPSO-BP算法可以对原始BP神经网络的冗余连接删除,精简网络结构,可以有效提高BP神经网络的收敛速度和精度<sup>[7]</sup>.IPSO是对粒子群算法改进,从学习因子和惯性权值两个方面改进后发现取得较好的效果.

## 2 实证研究

一般,我们取用拟和度和相对误差来验证各路段交通时间预测的精度,要求预测函数得出的结果值与真实值之间的相对误差在10%以内,这样在长度为600m的路段上,预测出的路段行程时间误差可以控制在12s以内.

### 2.1 模型的计算与分析

文章采用浙江省绍兴市柯桥区的路段作为研究对象, 24 个路段的路段 ID 与相对应的信息如表 1.

表 1 路段基本信息

路段 ID	道路	方向	路段开始	路段结束
214	镜水路	南向北	群贤路	裕民路
36	裕民路	东向西	镜水路	双渎路
97	云集路	西向东	湖西路	湖东路
165	湖西路	北向南	鉴湖路	万商路
96	万商路	东向西	湖西路	金柯桥大道
161	金柯桥大道	北向南	裕民路	兴越路
34	裕民路	东向西	双渎路	湖东路
27	裕民路	西向东	金柯桥大道	湖西路
32	裕民路	东向西	湖东路	湖中路
16201	金柯桥大道	南向北	钱陶公路	华齐路
2	华齐路	东向西	笛扬路	育才路
108	柯南大道	东向西	柯岩大道	金柯桥大道
186	湖中路	南向北	裕民路	钱陶公路
163	金柯桥大道	北向南	华齐路	钱陶公路
58	群贤路	东向西	金柯桥大道	笛扬路
137	笛扬路	南向北	山阴路	群贤路
62	群贤路	东向西	湖中路	湖西路
61	群贤路	西向东	湖西路	湖中路
155	金柯桥大道	南向北	山阴路	群贤路
67	群贤路	西向东	百舸路	镜水路
138	笛扬路	北向南	群贤路	山阴路
77	山阴路	西向东	金柯桥大道	湖西路
156	金柯桥大道	北向南	群贤路	山阴路
95	万商路	西向东	金柯桥大道	湖西路

#### 2.1.1 BPR 路阻函数算法与多元线性回归分析

对于上述路段行程时间的计算模型的验证数据取用上述 24 个路段, 分别提取卡口数据和视频检测数据来对各个模型使用算法并得到各自的参数. 算法过程通过 MATLAB 软件编程实现, 以群贤路上金柯桥大道到笛扬路这一路段为例, 在 BPR 路阻函数模型中, 根据公式(1), 真实路段行程时间与路段流量之间的关系可以通过拟合得出参数  $\alpha=0.7807$  和  $\beta=1.4239$ ; 在加入排队长度数据中, 传统的多元线性回归模型得出参数  $\beta_0=33.3$ ,  $\beta_1=106.13$ ,  $\beta_2=0.283$ ,  $\beta_3=2.82$ , 最终 BPR 函数中的决定系数为 75.67%, 相对误差为 0.202, 多元线性回归的决定系数为 79.66%, 相对误差为 0.143. 将上述参数代入(1)(2)公式计算 BPR 路阻函数路段行程时间估计值和多元线性多元线性回归回归函数路段行程时间估计, 并与真实路段行程时间对比, 如图 2.

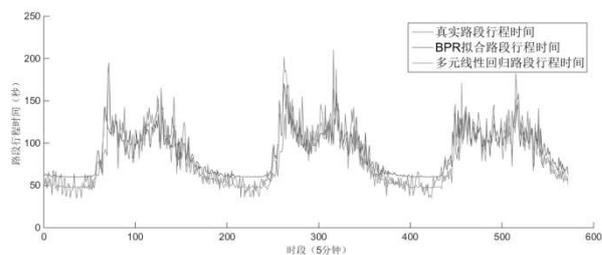


图 2 基于 BPR 函数、多元回归的路段行程时间估计与真值对比

图中的数据是连续三天的真实路段行程时间和回归路段行程时间, BPR 拟合路段行程时间的值域小于排队长度拟合路段行程时间, 也就是对于非常畅通和非常拥堵情况下 BPR 路阻函数估计值与真实值相差较大. 得出的相对误差也能表明多元线性回归模型的估计值更精确, 计算两者各个时间刻度真实值与估计值得相对误差可以表示为图 3.

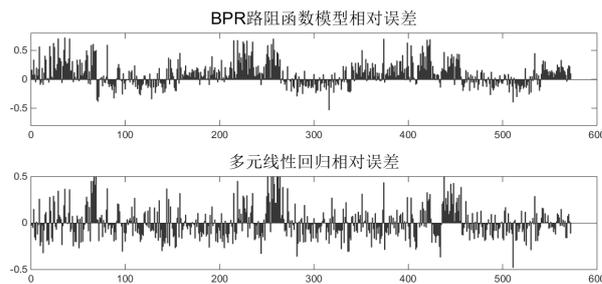


图 3 基于 BPR 函数、多元回归的路段行程时间相对误差

从图 3 可以看出, BPR 路阻函数估计模型的相对误差范围为(-0.8, 0.8), 排队长度回归模型的相对误差范围为(-0.5, 0.5), 同时 BPR 模型的相对误差大部分位于正数, 而多元线性回归相对误差正负分布较均匀, 可见 BPR 路阻函数模型并没有多元线性回归模型精确度高.

BPR 路阻函数是利用非拥挤条件下的高速公路数据建立的<sup>[8]</sup>, 算出的时间在早晚高峰时段并不能体现时间比平峰时段时间长的特性, 也就是算出来的行程时间没有办法判断一天中道路的拥堵状态情况. 原因是在路段拥堵的情况下, 流量很大, 在  $q/c=1$  的两边的时间变化坡度受到  $\beta$  值大小的影响,  $\beta$  越大, 时间变化越快; 在路段流量很少的情况下,  $\beta$  越大, 使得自由流时间  $t_f$  起到决定性的作用, 即时间不会随着流

量的变化而变化。另一原因是时间和流量并不完全正比，当路段非常拥堵时时间很长，流量也会很小，模型没有体现由畅通到拥挤这一过程中流量的变化即先增加后减少这个规律。

因此本文选择排队长度来计算路段行程时间，将信号交叉口的等待时间计算在内，提高城市道路路段平均行程时间的精度。

2.1.2 BP 神经网络算法

交叉口处的视频检测技术输入数据单位不一致，瞬时速度变化在[15-65]之间，检测流量在[0-130]之间，排队长度则是[0-45]之间，因此将输入层使用线性转换算法归一化后需要使用双曲正切 S 形函数激活，原因是线性转换算法的取值范围是[-1, 1]，激活函数值域范围也应该是[-1, 1]，训练算法使用变学习率动量梯度下降算法。确定 BP 神经网络参数后就可以对数据训练及仿真操作，反复训练样本数据的输入与输出得出网络结果(包含输各层的权值和阈值)，直到收敛。

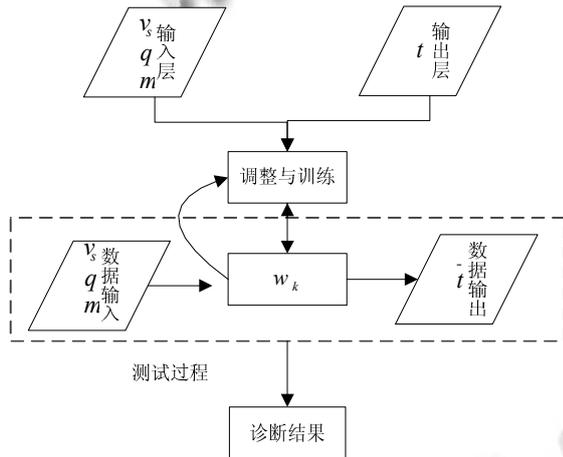


图 4 交通时间训练过程

$v_s$ 、 $q$ 、 $m$ 、 $t$  分别为瞬时速度、统计流量、排队长度、路段行程时间，将数据按照一定比例分为训练集、验证集和测试集， $t$  为预测路段行程时间。

2.1.3 改进 BP 神经网络算法

使用前人研究过的 IPSO-BP 算法调整 BP 神经网络的权重和阈值，得到需要用于计算路段行程时间的网络结构，通过对比分析各类算法结果，重点突出 IPSO-BP 算法用于交通时间计算的效果，并且分别将只有流量数据作为输入层(1 输入层)和流量、瞬时速度、排队长度数据作为输入层(3 输入层)分析，相应的结果对比如表 2。

表 2 算法结果对比

输入数据	1 输入层 BP	3 输入层 BP	3 输入层 IPSO-BP
输入层节点数	1	3	3
隐含层节点数	3	10	7
收敛代数	76	122	15
训练误差	0.051806	0.013526	0.006847
下降梯度	0.0574	0.132	0.0637
决定系数	0.81361 <sup>2</sup>	0.95373 <sup>2</sup>	0.96623 <sup>2</sup>

从上述结果可知，加入排队长度数据和改进的 BP 神经网络算法得到的决定系数比只有流量数据的算法高出 41.03%，也可以对比出比 BPR 路阻函数模型高出 23.37%，比 BP 神经网络高出 2.64%，因此训练出的网络模型效果较好。同时 IPSO-BP 算法在收敛代数上比 BP 神经网络算法明显减少，说明收敛的速度更快。将 986 条数据按照 60%训练集、20%验证集、20%测试集对比训练及仿真得出结果如图 5 和图 6 所示。

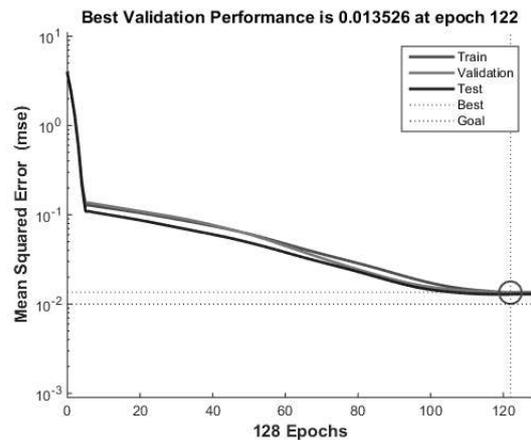


图 5 3 输入层 BP 神经网络训练结果

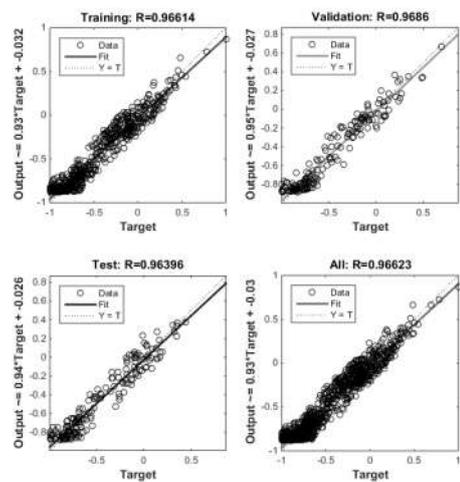


图 6 IPSO-BP 算法结果

从图 5 中看出训练集、验证集和测试集在训练过程中的趋势相同,说明网络具有良好的泛化能力,即训练出的 BP 神经网络具有较好的预测性能,图 6 为 IPSO-BP 算法的 3 个集合中的目标值与输出值之间的关系,当 Target 的系数接近于 1 并且 R 也接近于 1 时, BP 神经网络模型训练成功,可以用于仿真计算。

## 2.2 路段行程时间的预测

### 2.2.1 确定预测函数

时间序列模型预测路段行程时间是使用历史数据与实时数据建立的数学关系<sup>[8]</sup>,预测精度不仅取决于数据的周期相似性,同时还需考虑交通时间的变化性,因此路段行程时间的预测可表示为

$$S_{t-k} = T_0 + \sum_{i=1}^3 \lambda_i y_{t-k-i} + \sum_{j=1}^4 \gamma_j S_{t-j-k} \quad (3)$$

式中,  $S_{t-k}$  为第 t 周期第 k 时段的估计时间或者历史时间,  $y_{t-k}$  为 t 周期第 k 时段的实际行程时间,  $\lambda, \gamma$  为时间序列系数。

路段行程时间的预测过程中的数据来源是 IPSO-BP 算法仿真得出的路段行程时间,即路段行程时间历史数据,数据采用前 4 天的历史路段行程时间与前 3 个时段的行程时间,同样采用浙江省绍兴市柯桥区群贤路上金柯桥大道到笛扬路这一路段的数据为例,根据公式(3)可以拟合得出真实路段行程时间与拟合值之间的关系,通过比较真实值与拟合值,确定模型的可信度。

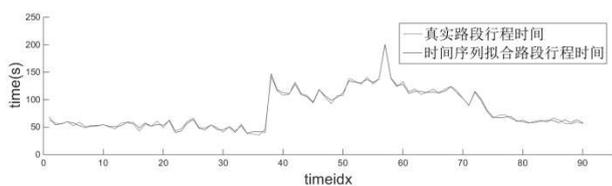


图 7 时间序列分析模型

图 7 为这一路段第 5 个周期各个时段的真实行程时间和拟合的行程时间,拟合函数为:

$$S_{5-k} = -0.98 + 0.217y_{5-k-1} + 0.199y_{5-k-2} - 0.064y_{5-k-3} + 0.197S_{4-k} + 0.262S_{3-k} + 0.136S_{2-k} + 0.052S_{1-k} \quad (4)$$

该路段的决定系数为 99.04%, 相对误差为 0.04, 同理,通过时间序列分析同样可以得到其他路段的行程时间估计,并计算各路段的决定系数和相对误差如表 3。

表 3 各路段的行程时间估计

路段 ID	214	36	97	165	96	161
决定系数(%)	99.31	90.52	98.03	93.49	98.65	98.57
相对误差	0.03	0.06	0.07	0.09	0.09	0.05
路段 ID	34	27	32	16201	2	108
决定系数(%)	93.89	91.79	92.84	97.24	94.51	92.90
相对误差	0.05	0.05	0.03	0.05	0.06	0.06
路段 ID	186	163	58	137	62	61
决定系数(%)	90.36	98.60	99.04	94.57	95.32	93.13
相对误差	0.07	0.07	0.04	0.08	0.09	0.06
路段 ID	155	67	138	77	156	95
决定系数(%)	97.96	90.07	92.08	90.28	98.30	96.02
相对误差	0.06	0.05	0.08	0.09	0.04	0.09

表中为柯桥区 24 个路段的行程时间的时间序列预测,在这些路段中,平均决定系数为 94.50%, 相对误差为 0.06. 表明该预测模型可以用于路段行程时间的预测研究。

### 2.2.2 预测

已知当前路段行程时间和历史路段行程时间,根据上述预测函数可以预测出下个时段的路段行程时间和下个周期的路段行程时间. 下个周期的预测结果是将预测得到的短期路段行程时间数据作为输入变量加入到模型中而得。

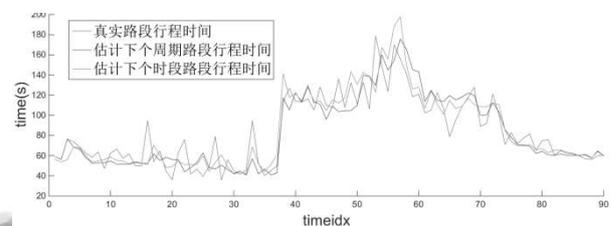


图 8 下个周期和下个时段的路段行程时间预测

图 8 为群贤路上金柯桥大道到笛扬路这一路段第 6 个周期的路段行程时间真实值和预测值,预测值分为整个周期的预测和已知上个时段的下个时段行程时间预测,下个周期的预测数据为历史周期的路段行程时间,下个时段的预测数据为历史周期及历史时段的路段行程时间. 得出结果为下个周期的路段行程时间预测决定系数为 81.02%, 相对误差为 0.14, 下个时段的路段行程时间预测决定系数为 93.59%, 相对误差为 0.13. 其他路段的行程时间预测相对误差如表 4, 其中 R-y 表示下个周期的预测相对误差, R-s 表示下个时段的预测相对误差。

表4 柯桥区部分路段的路段行程时间估计结果

路段 ID	214	36	97	165	96	161
R-y	0.19	0.11	0.18	0.15	0.19	0.11
R-s	0.15	0.11	0.15	0.15	0.16	0.12
路段 ID	34	27	32	16201	2	108
R-y	0.10	0.13	0.12	0.18	0.14	0.17
R-s	0.11	0.15	0.13	0.13	0.17	0.17
路段 ID	186	163	58	137	62	61
R-y	0.16	0.16	0.14	0.19	0.15	0.15
R-s	0.16	0.16	0.13	0.16	0.16	0.14
路段 ID	155	67	138	77	156	95
R-y	0.13	0.10	0.15	0.16	0.10	0.15
R-s	0.13	0.10	0.14	0.14	0.10	0.14

下个周期的路段行程时间预测平均相对误差为0.15, 下个时段的路段行程时间预测平均相对误差为0.14. 该预测并未考虑外来因素如未来天气、交通事故等对路段行程时间的影响, 一般来讲, 时间越近的预测的准确度越高.

### 3 结论与展望

根据本文结果, 在视频车辆检测器充足的情况下, 整个柯桥区的路段都能计算出路段行程时间, 同时还能预测出下个时段和下一个周期的交通时间, 通过进一步研究能完成以下内容: 出行时间预测、路段速度分析、拥堵状态监控和交通信号控制等.

由于视频检测器的费用昂贵, 此方法可以是路段行程时间计算的补充, 同时也是数据的充分利用, 在不同检测器下能有不同的计算方法得出路段行程时间. 微波线圈检测器可以根据路段速度及路段流量和延误

时间计算路段行程时间, 视频检测器根据排队长度、路口速度和路口流量, 卡口数据则直接根据车辆经过路段两端路口的时间差计算得出. 在城市道路中研究道路的拥堵情况时, 不同的数据来源都能得到较准确的路段行程时间结果, 同时当某种检测器数据缺失时, 可以通过其他检测器中数据算法插补缺失值.

### 参考文献

- 1 Foundation AS. Freeway-parking developments: A report for the united states department of commerce. Bureau of Public Roads, 1964.
- 2 Vanajakshi LD. Estimation and prediction of travel time from loop detector data for intelligent transportation systems applications. Texas A & M University, 2004.
- 3 刘宁, 赵胜川, 何南. 基于 BPR 函数的路阻函数研究. 武汉理工大学学报(交通科学与工程版), 2013, 37(3): 545-548.
- 4 姜桂艳, 李继伟, 张春勤. 城市主干路路段行程时间估计的 BPR 修正模型. 西南交通大学学报, 2010, 45(1): 124-129.
- 5 姚荣涵, 王殿海, 曲昭伟. 基于二流理论的拥挤交通流量排队长度模型. 东南大学学报(自然科学版), 2007, 37(3): 521-526.
- 6 Basheer IA, Hajmeer M. Artificial neural networks: Fundamentals, computing, design, and application. Journal of Microbiological Methods, 2001, 43(1): 3-31.
- 7 沈学利, 张红岩, 张纪锁. 改进粒子群算法对 BP 神经网络的优化. 计算机系统应用, 2010, 19(2): 57-61.
- 8 Harris RID, Sollis R. Applied time series modelling and forecasting. Financial Reporting & Loan Analysis Version. ed. sas Institute Inc, 2003: 115-138.