

信号控制交叉路口车辆排队长度

祁宏生,王殿海

(吉林大学 交通学院,长春 130022)

摘要:建立了一个能够估计市内信号交叉路口车辆实时排队长度的模型。分析了路段交通流之间的流向关系,根据流向关系建立了两种路段交通流影响模型:神经网络模型和贝叶斯网络模型,并描述了模型的结构。为了方便模型的实际应用,分别用主成份对输入变量降维,用EM算法和高斯混合分布函数来表达模型和训练模型参数。基于实际路网设计了一个仿真路网,并用不同的实验场景对模型进行有效性验证。仿真实验的结果表明,由于城市路网中存在的随机性,贝叶斯网络模型能够更好地把握交通流变化的趋势。

关键词:交通运输系统工程;交叉路口;排队;神经网络;贝叶斯网络;主成份分析

中图分类号:U491.1 **文献标识码:**A **文章编号:**1671-5497(2009)06-1457-06

Vehicle queue length at signal controlled intersection

QI Hong-sheng, WANG Dian-hai

(College of Transportation, Jilin University, Changchun 130022, China)

Abstract: A study was performed to estimate the real-time vehicle queue length before the stop line at the urban signal controlled intersection. The relationship among traffic flow directions in road sections was analyzed, and two models, i. e., an artificial neural network model and a Bayesian network model were established to deal with the effects of traffic flows in the road sections, and the structure of the models was specified. To facilitate the practical application of these models, the principal component analysis was used to decrease the input dimensions, the EM algorithm and GMM were used to represent the parameters of the train models. A simulation road network was designed based on the real world data to validate the proposed models under various experiment scenarios. Simulation results showed that the Bayesian network model can grasp the traffic flow tendencies better than the artificial neural network model because of the randomness in the urban road network.

Key words: engineering of communications and transportation system; intersection; queue; artificial neural network; Bayesian network; principal component analysis

排队是交通系统运行的重要指标,也是城市交通诱导系统的一个重要的输入参数^[1-2],因此获得城市交通系统中的实时排队长度很重要。周学农^[3]通过实测数据,分析了多个经典的排队模型的计算结果,并建立了符合长沙的排队长度优化

模型。荣建、何民等^[4]利用北京道路的实测数据,对比了国内外多种排队计算方法,针对北京的实际情况,建立了动态计算的排队模型。何宁等^[5]通过实证的研究方法,得到了大量的数据并拟合了适合于特定地区的定量关系式。上述模型大多

收稿日期:2008-09-16.

基金项目:“973”国家重点基础研究发展计划项目(2006CB705500).

作者简介:祁宏生(1983-),男,博士研究生. 研究方向:网络交通流理论. Email:lordqi@yahoo.cn

集中于平均排队或者最大排队,这些模型中比较经典的有 Miller、Akcelik、TRANSYT 等^[6]。城市交通系统是一个系统,即使在短时间内交通特征参数也可能发生剧烈的波动,突出表现是信号交叉口前的排队在一个周期内不停地聚集和消散。因此,上述排队模型或方法不能把握这种变化特征,有必要研究信号交叉口实时长度的估计方法。

由于各种原因(如成本原因、不能处处安装交通信息检测设备或系统故障等),无法获得某些路段的排队信息,因此,本文从交叉口相邻路段之间的流向关系出发,分别利用神经网络和贝叶斯网络建立了基于相邻路段关系的排队影响模型,并对之进行了比较,利用这两个模型可以从已知排队长度推断未知路段排队长度。结果表明,由于城市交通系统的随机性,基于贝叶斯网络的路段排队影响模型比神经网络模型更精确。

1 交通流关系描述及模型建立

图 1 为一典型的城市局部路网图,图中 A 代表交叉口, a 、 b 、 c 、 d 代表基本路段。整个城市路网可以看作是由图中的基本单元组成。要想描述城市路网交通流的关系,首先必须描述基本组成部分内交通流运行关系。

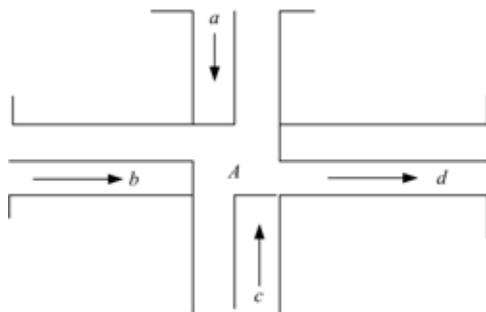


图 1 城市局部路网

Fig. 1 Local road network

从图中可知, d 路段上的交通流是路段 a 、 b 、 c 路段上的部分交通流组合而成,在不发生突发事件(交叉口的道路条件、信号条件、管理条件不变)的情况下,路段 d 上的交通流直接由路段 a 、 b 、 c 决定。可以将 a 、 b 、 c 路段上的交通流看作“输入”, d 路段上的交通流看作是“输出”,或者 a 、 b 、 c 路段上的交通流是 d 路段上交通流的原因,从这两个角度出发,如果 a 、 b 、 c 路段上的交通流信息已知(流量、延误、排队长度等)就可以推断出路段

d 上的交通流信息。

如图 2 所示,将图 1 的城市道路局部做了扩展。通过上述可知,路段 d 的交通流信息由路段 a 、 b 、 c 决定,同样,因为路段流向的关系,当其他条件(道路条件、控制条件、管理条件)不变时,路段 b 的交通流信息由路段 e 、 f 、 g 上的交通流状态决定。

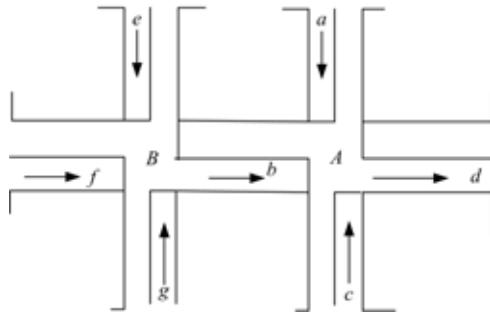


图 2 城市局部路网扩展

Fig. 2 Local road network extended

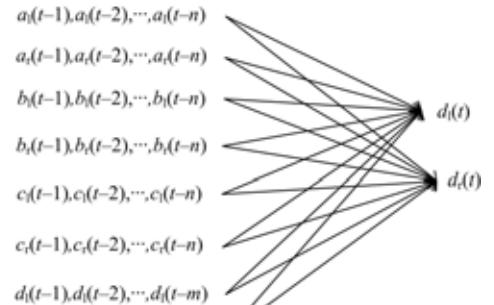
考虑到时间因素,某路段的交通流状态不仅受到相邻路段的影响,而且受到本路段之前某些时刻的交通流状态的影响,即应考虑到历史数据的影响。令 $d(t)$ 代表 t 时刻 d 路段上的排队,依此类推, $a(t)$ 、 $b(t)$ 、 \dots 分别代表各自路段上 t 时刻排队,用符号来表述相邻路段之间的关系,即: $d(t)$ 取决于 $a(t-1)$ 、 $a(t-2)$ 、 \dots $a(t-n)$; $b(t-1)$ 、 $b(t-2)$ 、 \dots $b(t-n)$; $c(t-1)$ 、 $c(t-2)$ 、 \dots $c(t-n)$; $d(t-1)$ 、 $d(t-2)$ 、 \dots $d(t-m)$, 其中 m, n 是整数。基于上述两种角度,分别建立基于神经网络^[7]的交通流影响模型和基于贝叶斯网络的交通流影响模型。考虑到每条路段都有相应的左转、直行、右转流量,本文构建了基于相邻路段的网络模型如图 3 所示。

图中,下标 l 和 r 分别表示左转、右转的交通流状态。如果某路段交通流状态信息缺失,假设路段 b 的信息丢失,由于 b 路段的交通流的状态由路段 e 、 f 、 g 路段的状态决定,可以利用两步骤预测方法得到路段 $d(t)$ 的状态(如图 4 所示):先利用 e 、 f 、 g 的状态得到 b 的状态,然后再利用 a 、 b 、 c 的状态得到 d 的状态。

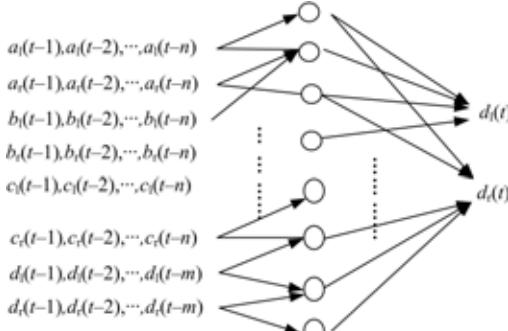
2 模型的训练和预测

为了能够利用模型获得路段排队长度,需要对之进行训练和检验。可以看出,模型的维数很大,如果 $m=5, n=5$, 输入变量就有 20 个,考虑到直行排队和左转排队则有 40 个。维数过大就会

给训练和预测带来困难, 因此利用主成份分析进行降维^[8]。



(a) 贝叶斯网络模型



(b) 神经网络模型

图 3 基于相邻路段的网络模型

Fig. 3 Network model based on adjacent roads

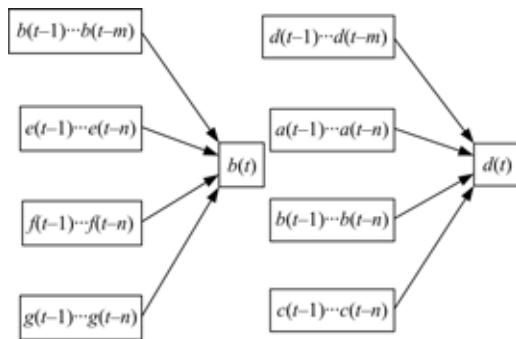


图 4 两步骤预测方法

Fig. 4 Two-step forecast

对于神经网络模型, 利用线性函数做为传递函数, 采用 BP 神经网络, 其参数训练采用梯度下降动量学习方法, 学习率为缺省值 0.01, 神经网络的隐层数目根据 Kolmogorov 定理为: $2 * \text{输入神经元数目} + 1$ 。对于贝叶斯网络模型, EM 算法^[9]是进行最大似然估计的有效算法, 能够在缺失数据下进行训练, 因此应用 EM 算法进行参数训练。其变量间的联合概率分布采用能够以一定精度逼近任何概率分布的混合高斯模型

$$p(\mathbf{X}) = \sum_{i=1}^l a_i G(x_i) \quad (1)$$

式中: $G(\cdot)$ 为高斯函数。

设输入(即上游各路段的交通流状态)为 \mathbf{x}_E , 输出(即下游路段的交通流状态)为 \mathbf{x}_F , 根据最小均方差原则, 从 \mathbf{x}_E 中得到的 \mathbf{x}_F 的最佳估计为

$$\hat{\mathbf{x}}_F = E(\mathbf{x}_F | \mathbf{x}_E) \quad (2)$$

式(2)即为从上游路段得到下游路段状态的基础公式。为了推导(2)的具体表达, 设 $G(x; \mu, \Sigma)$ 表示多元高斯概率密度函数, 其均值矩阵为 $\mu^T = (\mu_E^T, \mu_F^T)$, 协方差矩阵为 $\Sigma = \begin{pmatrix} \Sigma_{EE} & \Sigma_{EF} \\ \Sigma_{FE} & \Sigma_{FF} \end{pmatrix}$, 根据

条件概率公式可得

$$p(\mathbf{x}) = G(\mathbf{x}_E; \mu_E, \Sigma_{EE}) G(\mathbf{x}_F; \mu_F, \Sigma_{FF}) \quad (3)$$

式中: $\mu_{x_F|x_E} = \mu_F - \Sigma_{FE} \Sigma_{EE}^{-1} (\mu_E - x_E)$, $\Sigma_{x_F|x_E} = \Sigma_{FF} - \Sigma_{EE}^{-1} \Sigma_{EF}$ 。则根据式(3), 可得

$$p(\mathbf{x}_F, \mathbf{x}_E) = \sum_{l=1}^M a_l G(x; \mu_l, \Sigma_l) = \sum_{l=1}^M a_l G(\mathbf{x}_E; \mu_{lE}, \sum_{lEE}) G(\mathbf{x}_F; \mu_{lF1E}, \Sigma_{lF1E}) \quad (4)$$

条件概率为

$$p(\mathbf{x}_F | \mathbf{x}_E) = \frac{\sum_{l=1}^M a_l G(\mathbf{x}_E; \mu_{lE}, \Sigma_{lEE}) G(\mathbf{x}_F; \mu_{lF1E}, \Sigma_{lF1E})}{\sum_{j=1}^M a_j G(\mathbf{x}_E; \mu_{jE}, \Sigma_{jEE})} \quad (5)$$

其中:

$$\mu_{lF1E} = \mu_{lF} - \Sigma_{lFE} \Sigma_{lEE}^{-1} (\mu_{lE} - x_E)$$

$$\Sigma_{lF1E} = \Sigma_{lFE} - \Sigma_{lFE} \Sigma_{lEE}^{-1} \sum_{lEF}$$

则根据式(2)、式(5)可得在最小均方差下 x_F 的最佳估计(即下游路段的状态值):

$$\hat{\mathbf{x}}_F = E(\mathbf{x}_F | \mathbf{x}_E) = \sum_{l=1}^M \frac{a_l G(\mathbf{x}_E; \mu_{lE}, \Sigma_{lEE})}{\sum_{j=1}^M a_j G(\mathbf{x}_E; \mu_{jE}, \Sigma_{jEE})} \quad (6)$$

式(6)即为输入 \mathbf{x}_E 和输出 \mathbf{x}_F 的关系, 二者分别代表上游各路段状态和下游路段的交通状态。

3 模型的模拟验证

利用 VISSIM 微观软件对模型进行验证, 建立的局部路网如图 5 所示, A 交叉口配时方案仿照长春市自由大路—同志街交叉口配时方案, B 交叉口配时方案仿照自由大路—人民大街交叉口

配时方案(根据实际调查得配时数据如表1)。定义采集时间间隔内的排队长度是该间隔内的平均排队长度。考虑到实际路网中有左转和直行排队,每个流向都分为直行排队和左转排队。

本文进行路段排队长度估计的步骤为:①选择输入变量(原因节点)和输出变量(结果节点),

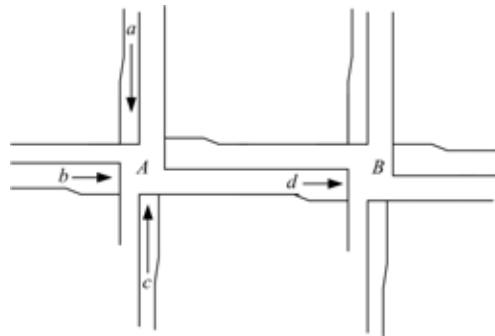


图5 模拟路网

Fig. 5 Simulated road network

构建路段排队影响模型;②通过模拟获得数据,提取出主成份,对步骤①构建的两个网络模型进行训练;③利用训练好的网络进行预测。

设模拟排队长度值为向量 $\mathbf{x} = [x_1, x_2, x_3, \dots, x_n]$,估计向量为 $\mathbf{y} = [y_1, y_2, y_3, \dots, y_n]$,为了评价两种方法的优劣,引入平均误差

$$\text{AE} = \frac{\sum_{i=1}^n |(y_i - x_i)|}{n}$$

为了设计不同的试验场景,以调查的基准流量为1,分别乘以不同的系数 α 验证模型,当 α 大于2时,交叉口已经过饱和,因而分别取 $\alpha=1, 1.5, 2$ 三种设计场景。取 $m=5, n=5$ (即考虑本时刻以上的5个时段的历史数据,本模拟试验的时段选择10 s),进行主成份分析。考虑到直行和左转,共8个流向,则输入维数为40个($8 * 5$),输出变量有两个(分别为直行排队和左转排队),对

表1 交叉口A和B的配时方案

Table 1 Signal set of intersection A and B

(A交叉口)相位/s	绿灯/s	黄灯/s	红灯/s	(B交叉口)相位/s	绿灯/s	黄灯/s	红灯/s
东西直行	73	3	68	东西直行	48	2	94
东西左转	23	2	119	东西左转	23	2	119
南北直行左转	41	2	97	南北直行	40	3	101
——	——	——	——	南北左转	24	2	118

于 $\alpha=1$ 这种试验场景来说,各个主成份的贡献率如图6所示。

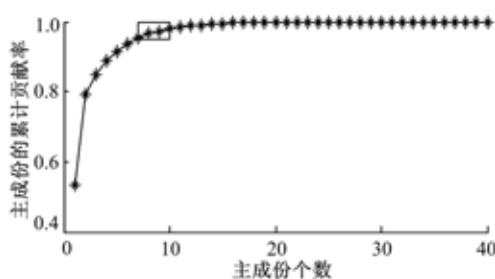


图6 主成份累计贡献率

Fig. 6 Accumulated contribution of component

由图6可以看出,前7个主成份的贡献率达到95%,图上部方框后的主成份对向量组的贡献率没有太大的改观,选取前7个主成份来代替40个变量。则模型的输入都有7个变量,输出有2个变量。神经网络的隐层定为 $2 \times 7 = 15$ 个。以 AE_n 代表直行排队的神经网络模型的平均估计误

差, AE_b 代表直行排队的贝叶斯网络模型的平均估计误差,模型估计的结果如图7所示。

可见,不管在何种试验场景(低流量或高流量)之下,二者都能反映排队长度的变化趋势。误差基本在 ± 10 m 以内(误差图的上下直线之间),整体上贝叶斯网络的预测结果更准确一些。但神经网络的运算时间与贝叶斯网络相比较快一些。

4 结束语

分别利用神经网络和贝叶斯网络对城市路网相邻路段进行建模,用已知信息估计未知信息。模拟结果显示,由于城市路网中的随机性,贝叶斯网络模型显然更能够把握相邻路段之间的数量关系,且比神经网络更具备适应性,但其实时性不如神经网络。本文只是得到了信号控制交叉口排队长度数量上的变化关系,而不是从根本上揭示其机理,要建立其本质上的关系需要详细考虑道路条件、信号控制条件、交通管理条件等因素。

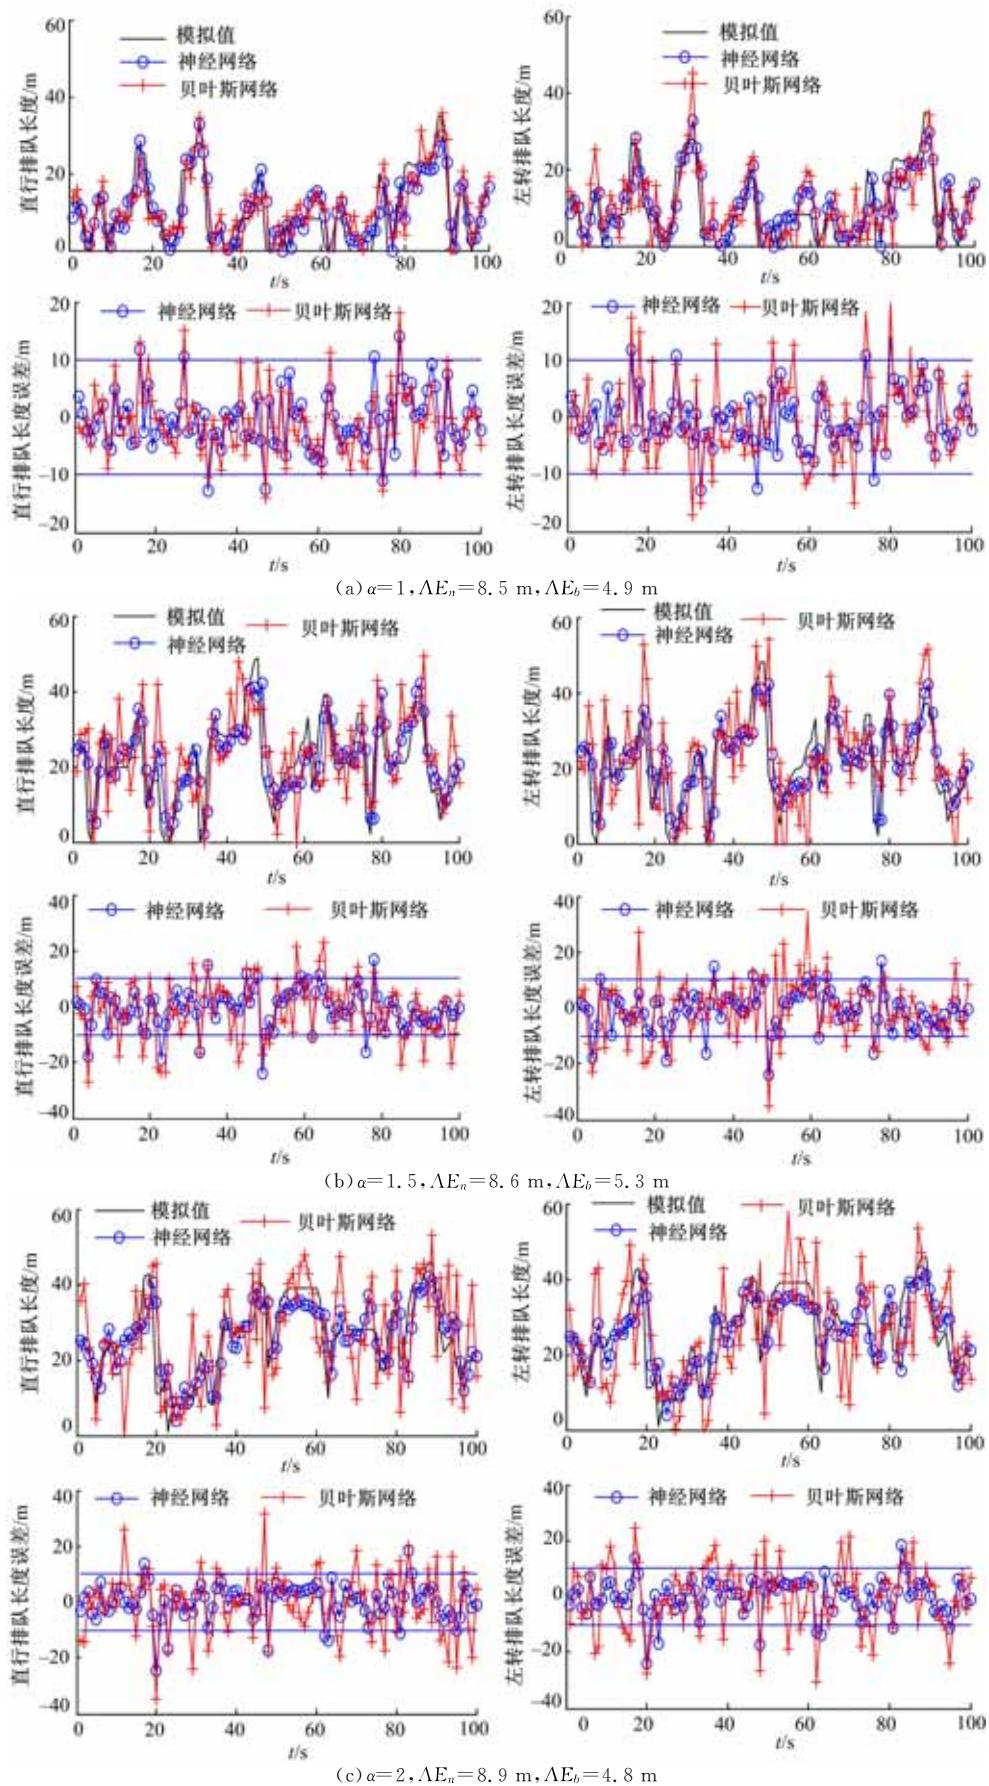


图 7 排队估计结果
Fig. 7 Results of queue

参考文献:

- [1] 陆化普. 智能运输系统[M]. 北京: 人民交通出版社, 2002.
- [2] 周溪召, 范炳全. 动态路线行程时间研究[J]. 上海理工大学学报, 1999, 21(4): 385-388.
Zhou Xi-zhao, Fan Bing-quan. Study on dynamic path travel time[J]. Journal of University of Shanghai for Science and Technology, 1999, 21(4): 385-388.
- [3] 周学农. 排队长度模型比较及动态方法研究[J]. 交通运输系统工程与信息, 2006, 6(1): 91-95.
Zhou Xue-nong. Queue length model comparison and dynamic modeling[J]. Transportation Systems Engineering and Information, 2006, 6(1): 91-95.
- [4] 荣建, 何民, 陈春妹. 信号交叉口排队长度动态计算方法研究[J]. 中国公路学报, 2002, 15(3): 101-104.
Rong Jian, He Min, Chen Chun-mei. Dynamic model of calculating queue length at signalized intersection [J]. China Journal of Highway And Transport, 2002, 15(3): 101-104.
- [5] 何宁, 杨涛, 李朝阳, 等. 信号交叉口延误及排队长度实证研究[J]. 公路交通科技, 2002, 19(5): 106-109.
He Ning, Yang Tao, Li Chao-yang, et al. Positive research and application of signal intersection traffic delay and queue length[J]. Journal of Highway and Transportation Research and Development, 2002, 19 (5): 106-109.
- [6] Myst Kowski C, Khan S. Estimation queue length using Signal94, Synchro3, Transyt-7F, Passer II-90, and Corsm[C] // The 78th Transportation Research Board Annual Meeting, Transportation Research Board, Washington, 1999.
- [7] 侯媛彬, 杜京义, 汪梅. 神经网络[M]. 西安: 西安电子科技大学出版社, 2007.
- [8] Jolliffe I T. Principal Component Analysis[M]. New York: Springer, 1986.
- [9] Dempster A P, Laird N M, Rubin D B. Maximum likelihood from incomplete data via the EM algorithm[J]. Journal of the Royal Statistical Society, 1997, 39(1): 1-38.