

控制与决策

Control and Decision

区分交通流模式的混合服务路口信号控制策略

童林, 官铮, 杨文韬, 祝昆

引用本文:

童林, 官铮, 杨文韬, 等. 区分交通流模式的混合服务路口信号控制策略[J]. *控制与决策*, 2021, 36(6): 1509–1515.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2019.1520>

您可能感兴趣的其他文章

Articles you may be interested in

基于FWADE-ELM的短时交通流预测方法

Short-term traffic flow forecasting based on hybrid FWADE-ELM

控制与决策. 2021, 36(4): 925–932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

基于FWADE-ELM的短时交通流预测方法

Short-term traffic flow forecasting based on hybrid FWADE-ELM

控制与决策. 2021, 36(4): 925–932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

基于强化学习的倒立摆分数阶梯度下降RBF控制

Reinforcement learning based fractional gradient descent RBF neural network control of inverted pendulum

控制与决策. 2021, 36(1): 125–134 <https://doi.org/10.13195/j.kzyjc.2019.0816>

基于改进萤火虫算法的区域交通信号配时优化

Timing optimization of regional traffic signals based on improved firefly algorithm

控制与决策. 2020, 35(12): 2829–2834 <https://doi.org/10.13195/j.kzyjc.2019.1835>

一类非线性大系统分散自适应预设性能有限时间跟踪控制

Decentralized adaptive prescribed performance finite-time tracking control for a class of large-scale nonlinear systems

控制与决策. 2020, 35(12): 3045–3052 <https://doi.org/10.13195/j.kzyjc.2019.0623>

区分交通流模式的混合服务路口信号控制策略

童林^{1,2}, 官铮^{1†}, 杨文韬², 祝昆²

(1. 云南大学 信息学院, 昆明 650091; 2. 六盘水师范学院 物理与电气工程学院, 贵州 六盘水 553004)

摘要: 相对于固定配时, 基于交通流的动态变化特征的信号配时算法具有更好的道路状态适应性. 鉴于此, 提出一种基于交通流识别的自适应控制策略, 首先利用自组织映射网络(SOM)神经网络对历史交通流状态聚类, 结合路口时间段与路段环境特征分析实现交通流模式划分; 在此基础上, 引入概率神经网络(PNN)对该路口的交通流模式进行训练学习; 最后针对不同状态类型交通流量, 动态选取门限服务轮询信号配时和韦伯斯特信号配时策略计算信号灯配时周期, 实现控制策略与交通流动态变化特征的匹配. 仿真实验结果表明, 区分交通流模式的混合服务路口信号控制方法对车流的随机变化具有更好的适应性.

关键词: 交通流; 自组织映射网络; 概率神经网络; 门限轮询; 韦伯斯特配时

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2019.1520

开放科学(资源服务)标识码(OSID):



引用格式: 童林, 官铮, 杨文韬, 等. 区分交通流模式的混合服务路口信号控制策略[J]. 控制与决策, 2021, 36(6): 1509-1515.

Signal control strategies of mixed service intersections to discriminate traffic flow patterns

TONG Lin^{1,2}, GUAN Zheng^{1†}, YANG Wen-tao², ZHU Kun²

(1. School of Information Science and Technology, Yunnan University, Kunming 650091, China; 2. School of Physics and Electrical Engineering, Liupanshui Normal University, Liupanshui 553004, China)

Abstract: Compared with the fixed timing, the signal timing algorithm based on the dynamic change characteristics of traffic flow has better road state adaptability. Therefore, this paper proposes an adaptive control strategy based on traffic flow identification, firstly the self-organizing mapping network (SOM) neural network is used to cluster the historical traffic flow state, and the environment feature analysis of the intersection time segment and the road segment is combined to realize the traffic flow mode division. On this basis, the probabilistic neural network (PNN) is introduced to train the traffic flow pattern of the intersection. Finally, according to the traffic flow of different state types, the threshold service polling signal timing and Webster signal timing strategy is dynamically selected to calculate the signal lamp timing period, and the matching between the control strategy and the traffic flow dynamic change characteristics is realized. The simulation results show that the mixed service intersection signal control method, which distinguishes the traffic flow mode, has better adaptability to the random variation of traffic flow.

Keywords: traffic flow; self-organizing map; probabilistic neural network; threshold polling; Webster timing

0 引言

在道路基础设施建设相对固定的情况下, 合理的交通信号控制策略可有效缓解交通路口拥堵状况, 减小行车延误. 随着城市规模的扩大, 大中型城市的路网已经覆盖到距离市区较远的区域, 城市功能区的分布不均, 使得不同区域的路口之间流量高峰到达时间、流量峰值和波动特征等方面存在较大差异. 例如,

在居住人口密集的城郊区域, 其道路早高峰期将提前于活动密集的城市中心区域, 晚高峰则滞后. 基于全局的定时信号控制灵活性较低, 难以适应实际交通系统的需求, 而感应配时大多利用短时局部信息, 存在调控滞后性^[1]. 利用城市道路高峰时间及流量分布、路段信息车流波动统计等交通实时监测及历史统计数据对交通流状态识别, 能较好地实现交通流特征

收稿日期: 2019-10-31; 修回日期: 2020-04-03.

基金项目: 国家自然科学基金项目(61761045); 云南省应用基础研究计划项目(2017FB100); 六盘水师范学院硕士培育点项目(LPSSYSSDPY201704); 六盘水师范学院重点专业项目(LSZDZY2018-03).

责任编委: 郭戈.

†通讯作者. E-mail: gz_627@sina.com.

与交通信号控制策略的匹配,达到交通信号动态协调控制的目的.

聚类技术被广泛用于交通状况分析和发现巨大交通数据中的隐藏结构,实现交通拥堵分类和交通量预测^[2-3]. 但该方法适合针对车流量时变性较强的路口进行评价,缺乏对控制策略的研究,而控制策略的研究是智能交通中信号控制的关键. 定时信号控制中普遍采用的是韦伯斯特信号配时方法,以交通延误最小为目标求解最佳周期时长与各相位绿信比. 文献[4-5]将改进的韦伯斯特配时算法引入到交通信号控制中,取得了较好的控制效果. 然而,经过优化的固定绿信比信号配时实质上仍是固定配时,应用在路口车流量分布离散时车辆延误较高. 感应信号控制研究中,Boon等^[6]提出了完全服务控制方式下的车辆驱动策略. Li等^[7]采用基于深度强化学习设计的交通信号能够灵活地学习和响应不同的交通状况. 文献[8]采用遗传算法优化交通信号定时参数和激励信号设置. 齐驰等^[9]基于排队长度均衡优化信号配时. 总体上,智能算法对硬件与时间成本要求较高,路口需要独立的解决方案执行信号配时才能达到效果最优,存在控制算法复杂度高、模型计算量大的问题.

本文提出一种区分交通流模式的混合服务路口信号控制策略. 该方法基于路口流量历史统计和实时采集数据,利用SOM和PNN神经网络实现路口流量模式划分及识别. 通过流量模式与韦伯斯特配时和门限服务轮询配时算法的动态匹配,克服单一控制方案缺乏适应不同路口的交通分布差距与交通流时变性强的难点,实现与道路通行状态相适应的交通信号动态协调控制. 本文的创新之处在于:通过路段交通数据充分挖掘交通流模式的内在特点,实现动态交通流的模式划分及快速识别. 此外,提出自适应交通信号配时策略,在传统的韦伯斯特控制策略基础上进行基于交通流模式的信号周期和相位优化,并补充通信数据分发中的门限服务轮询控制策略,在轮询系统易饱和时可以切换到韦伯斯特配时,避免了站点过饱和现象,在保证精度和效率的同时,能够根据交通流的需求变化自适应动态学习.

1 控制模型

本文所提出控制模型可以分为以下两个部分:

1) 交通流模式划分及识别采用SOM与PNN神经网络. SOM网络是一种无监督学习网络,可以在没有任何分类信息的条件下,自适应地学习模式在输入空间中的分布特性^[10],从而改善现有交通时段划分的主观性. PNN网络训练时间短且分类能力强,在

模式分类问题中得到了广泛应用^[11]. 基于此,采用这两种神经网络对交通流聚类学习与识别,能够节约时间并减少控制策略的算法复杂度. 在此基础上,利用SOM网络对历史交通流模式进行划分和分析,最后实地采集了不同日期的不同时段交通流信息作为测试样本送入PNN神经网络对交通流在线识别.

2) 交通信号控制策略动态匹配基于交通流模式的识别结果,动态匹配与该类交通流模式相适应的交通信号控制策略. 考虑到经典的韦伯斯特配时方案时间灵活性较差,在此基础上提出基于交通流优化的韦伯斯特配时方案. 由于单独的控制策略无法满足交通流差异性与时变性,最后结合两种控制策略优缺点分析,根据交通流特点为不同类别的交通流接入不同控制策略,使不同的交通流模式对应不同的控制策略,做到配时跟着流量走.

2 交通流模式划分与识别

2.1 极大熵交通流OD矩阵估计模型

描述车辆由进口起始点到出口终止点在空间上分布的交通出行矩阵称为OD矩阵(origin-destination matrix). 动态OD矩阵反映一段时间内的交通需求,为后续交通流分配奠定基础.

路口模型如图1所示, O_i 代表出发路段, D_j 代表到达路段. 定义 $q_{ij}(\Delta t)$ 为第*i*个入口到第*j*个出口的交通流量大小,取时间间隔 $\Delta t = 15 \text{ min}$,为方便描述,下文中出现的 $q_{ij}(\Delta t)$ 均用 q_{ij} 替代. 图1中,忽略交叉路口车辆右转和掉头,动态OD矩阵可以写为

$$OD = \begin{bmatrix} 0 & 0 & q_{13} & q_{14} \\ q_{21} & 0 & 0 & q_{24} \\ q_{31} & q_{32} & 0 & 0 \\ 0 & q_{42} & q_{43} & 0 \end{bmatrix}. \quad (1)$$




图1 路口车流出发到达模型

众多的求解OD矩阵的模型中,热力学中熵原理的极大熵模型因其求解过程简单、估计精度较高被广泛应用. 在交通网络中,车辆的运动状态具有随机性,一种OD交通结构 $\{q_{ij}\}$ 是由所有随机交通事件所造成的, n 为OD对个数,那么随机交通事件总数为

$$T = \sum_{i=1}^n \sum_{j=1}^n q_{ij}. \quad (2)$$

如果将随机交通事件总数 T 标上不同的记号, 记号的一种排列分布构成的 OD 交通结构称为一种状态, 则一种交通结构对应着多个状态. 随机交通事件总数 T 为常数, 产生一种 $\{q_{ij}\}$ 对应的状态数为

$$N(q_{ij}) = T! / \prod_{i=1, j=1}^n q_{ij}! \quad (3)$$

按照极大熵的思想, 实际中最可能存在的 OD 矩阵是 $N(q_{ij})$ 熵值最大的矩阵, 使 $N(q_{ij})$ 值最大, 可得

$$\begin{aligned} \max \ln N(q_{ij}) &= T! / \prod_{i=1, j=1}^n q_{ij}! = \\ \ln T! - \sum_{i=1}^n \sum_{j=1}^n \ln q_{ij}! \end{aligned} \quad (4)$$

利用 Stirling 逼近公式 $\ln x! = x \ln x - x$ 简化式 (4), 得到

$$\max N(q_{ij}) = - \sum_{i=1}^n \sum_{j=1}^n (q_{ij} \ln(q_{ij}) - q_{ij}) \quad (5)$$

以路段的交通流量为最大熵模型的约束条件^[4], 建立如下 OD 矩阵估计模型:

$$\begin{aligned} \max N(q_{ij}) &= - \sum_{i=1}^n \sum_{j=1}^n (q_{ij} \ln(q_{ij}) - q_{ij}); \\ \text{s.t. } V_k &= \sum_{i=1}^n \sum_{j=1}^n q_{ij} p_{ij}^k, \quad k=1, 2, \dots, l, \quad q_{ij} \geq 0. \end{aligned} \quad (6)$$

其中: V_k 为路段 k 的交通量; 出发路段 O_i 和到达路段 D_j 的路段总数 $l = 8$, 本文记 $[V_k]_{k=1}^{l=8} = [O_1(t), O_2(t), O_3(t), O_4(t), D_1(t), D_2(t), D_3(t), D_4(t)]^T$; p_{ij}^k 为 OD 对 i, j 间通过路段 k 上的交通出行比例. 约束条件 p_{ij}^k 矩阵为

$$p_{ij}^k = \begin{bmatrix} 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 \\ 0 & 0 & 1 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 1 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 1 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (7)$$

其中: 横坐标 $(p_{13}^k, p_{14}^k, p_{21}^k, p_{24}^k, p_{31}^k, p_{32}^k, p_{42}^k, p_{43}^k)$ 表示出发到达区间, 纵坐标表示路段 k .

建立拉格朗日函数解决式 (6) 的复杂非线性问题, 有

$$\begin{aligned} L &= - \sum_{i=1}^n \sum_{j=1}^n (q_{ij} \ln(q_{ij}) - q_{ij}) + \\ &\sum_{k=1}^l \mu_k \left[V_k - \sum_{i=1}^n \sum_{j=1}^n q_{ij} p_{ij}^k \right] \end{aligned} \quad (8)$$

对式 (8) 求取偏微分方程且令偏微分方程为 0,

拉格朗日乘子系数 u_k 可通过联立式 (6) ~ (9) 获得^[12], 最终得到最优的交通流 OD 矩阵估计结果为

$$q_{ij} = \exp \left(- \sum_{k=1}^l u_k p_{ij}^k \right) \quad (9)$$

2.2 基于 SOM 网络的交通流模式划分

在交通流模式定义上, 传统方法依靠人工划分时段主观性较高, 缺乏对各个路口的交通流模式差异化和精细化定义. 为了克服人工划分交通时段的不合理性, 文献 [13] 使用 K -means 对交通数据聚类, 但在路口环境较复杂情况下难以预知交通类别 c 的数目. 使用基于人工免疫算法的交通时段划分方法存在缺乏对关键参数的优化等问题^[14]. 使用基于密度的聚类算法识别交通流组的问题在于交通流波动较大时样本间密度不均匀时聚类效果差^[15]. 由于自组织映射 (SOM) 网络学习过程中某些节点会不被激活, 在路口环境信息不明确下无需定义交通类别个数, 能够自动寻找数据规律映射到网络的二维平面上. 该模型由 Teuvo Kohonen 在 1981 年首次提出. 自组织映射网络结构分为两层, 第 1 层为输入层, 第 2 层为输出层, 负责对输入数据分析比较寻找规律并归类^[16].

以昆明市景明南路与聚贤街交叉口路段环境下 2018 年 12 月 30 日实测交通数据为样本, 应用 SOM 神经网络对交通样本模式聚类步骤如下.

step 1: 以 15 min 为单位将 24 h 交通数据划分成 96 组, 并进行基于极大熵原理的交通流 OD 矩阵估计, 获得动态交通流 OD 矩阵 $Q = (q_{13}, q_{31}, q_{14}, q_{32}, q_{42}, q_{24}, q_{43}, q_{21})$.

step 2: 对网络神经元权值 $w_j = (w_{j1}, w_{j2}, \dots, w_{jn})$ 赋予较小的随机值, j 为输出层神经元个数, 初始化学习速率 $\alpha(t, N)$ 、初始领域 $N_{j*}(0)$ 、循环次数 T .

step 3: 将动态交通流 OD 矩阵 Q 输入到 SOM 神经网络中, 对权值向量 w_j 与输入向量 Q_i 归一化操作, 并计算两者的点积, i 为交通数据样本个数.

step 4: 选中欧氏距离最近的神经元为获胜神经元, 更新获胜的神经元及其领域节点的连接权值, 有

$$w_j(t+1) = w_j(t) + \alpha(t, N)(Q_i - W_j(t)) \quad (10)$$

step 5: 令 $t = t + 1$ 并返回 step 3, $t = T$ 结束.

动态交通流矩阵经过 SOM 网络聚类 1 000 次后的结果如图 2 所示. 可以看出, SOM 网络能够较好地完成对交通中车流量数据的分类, 同时可以调整分类类别, 满足不同路口的交通状况. 根据聚类情况对车流量分布状态进行分析得到交通流模式中车流量分布特点如表 1 所示.




图2 交通流模式聚类效果

表1 交通流模式中车流量分布特点

交通流类别模式	路口车流量分布特点
F_1	车流量极低
F_2	车流量小且分布离散
F_3	车流量小且分布均匀
F_4	交通流量大且偏向于在东西方向
F_5	交通流量大且集中于南北方向

2.3 基于PNN网络的交通流模式识别

SOM网络是一种无监督学习模型,需要用有监督学习模型提取道路短时交通流模式.选择概率神经网络(PNN)在线识别交通流类别,概率神经网络由Specht在1990年首次提出.与其他有监督网络分类器相比,PNN速度较快,效果较好,适合对数据的处理和分类,能够做到对学习样本较为准确的学习和训练.基本的PNN网络各个网络层功能如下:输入层作为输入的神经网络层,其功能是将数据传递给模式层,输入数据 Q 的维数 d 与输入层的维数一致.模式层是该神经网络的核心之一,有 F_j 个模式类即神经元($j = 1, 2, \dots, c$),负责将输入的特征向量与输出类别的对应关系分别计算.该层采用 $e^{(Q^T w_j - 1)/\sigma^2}$ 作为神经元激活函数, w_j 为连接权重, σ 为平滑系数.该层第 j 类第 r 个神经元输出的概率为

$$\varphi_{jr}(Q) = \frac{1}{(2\pi)^{d/2} \sigma^d} \exp \left[-\frac{(X - X_{jr})^T (X - X_{jr})}{2\sigma^2} \right]. \quad (11)$$

其中: d 为训练数据的维度, α 为平滑系数, x_{jr} 为类 j 的第 r 个训练样本, $j = 1, 2, \dots, c, r = 1, 2, \dots, N_j, N_j$ 为类 j 的训练样本个数.求和层将相似类别的神经元进行概率求和,然后将概率密度作为该类别的求和结果.第 j 类类别的概率密度函数为

$$f_j = \frac{1}{N_j} \sum_{r=1}^{N_j} \varphi_{jr}(Q). \quad (12)$$

输出层由竞争神经元构成,负责在输出层的所有神经元中采用贝叶斯分类规则,寻找到具有最大后验概率的神经元^[17]标记为1,并作为类别 F_j 输出,其余神经元输出为0.

利用PNN神经网络分别对交通流进行训练与在

线识别,考虑到实际交通流数据有一定差异,采集不同日期与时间段交通流数据验证网络准确性.为充分说明PNN网络识别交通流类别的优势,选取经过SOM网络模式定义的交通数据为学习样本,并采集不同日期下的交通数据作为测试样本,选取常见的机器学习分类器如决策树、 K 最近邻(KNN)、支持向量机(SVM)进行性能对比,结果如表2所示.

表2 4种分类器对识别交通流模式识别的性能对比

识别方法	正确率/%	时间消耗/s
决策树	92.7	0.2189
KNN	93.8	0.2282
SVM	95.8	0.8488
PNN	96.3	0.2021

由表2可知,在同一学习样本下,PNN网络在识别正确率和时间消耗上均优于其他3种分类器,可以较为准确地识别路口中交通流模式的动态变化,时间上能够满足交通信号控制的实时性.

2.4 区分交通流模式的自适应控制策略

2.4.1 控制策略分析

1) 韦伯斯特控制策略.

韦伯斯特信号配时基于路口车流量历史分布状态进行^[18].已知交通流模式特点,可以根据交通流模式分布规律分别选取合适的相位、周期和绿信比进行最优配时,并记录每个交通模式对应的最优信号配时方案,作为预备方案存储在信号控制机中.设路口划分为 n 个相位,配时公式如下:

最短周期时长 C_m 为一个信号周期内完成车辆全部放行的时间周期,计算公式如下:

$$C_m = \frac{L}{1 - \sum_{i=1}^n y_i} = \frac{L}{1 - Y}. \quad (13)$$

其中: L 为一个信号周期总损失时间,有

$$L = \sum_{i=1}^n (l_i + I_i - A_i), \quad (14)$$

l 为车辆启动损失时间, I 为绿灯间隔时间, A 为黄灯时间, i 为一个周期内的相位数; y_i 为第 i 个相位上交通量最大的车道交通流量比; Y 为全部相位的最大流量比之和,且 $Y = \sum_{i=1}^n y_i$.当 $Y > 0.9$ 时,路口车辆处于严重过饱和状态,应重新对路口进行相位分配.

C_w 是指使路口行车延误最低的最佳周期时长,韦伯斯特以延误为交通效益指标求得最佳周期时长

$$C_w = \frac{1.5L + 5}{1 - Y}. \quad (15)$$

绿信比为有效绿灯时间 g_i 占可利用信号周期时间($C_w - L$)的比例,有效绿灯时间为

$$T_i = \frac{y_i}{Y}(C_w - L). \quad (16)$$

2) 门限服务轮询控制策略.

在线配时着重于周期与绿信比的分配,参照车辆驱动门限轮询控制策略^[19],各相位绿灯周期根据排队车辆数计算,绿灯时长等于当前绿灯周期开始时刻排队车辆通过路口所需时间的总和.若绿灯期间有新车辆到达,则等待下一个信号周期通行.考虑车辆批量到达特性,设路口划分为 N 个相位,考虑多车道情况下车辆到达存在批量达到特征,引入 α_i 为相位 i 批量达到的车辆均值, β_i 为相位 i 车辆的通过率, γ_i 为相位 i 黄灯时间, λ_i 为相位 i 车辆到达率. L_{th} 为每轮绿灯期允许通过的最大车辆数. $\rho_i = \alpha_i \beta_i \lambda_i$. 通过轮询模型对控制策略性能分析得出车辆平均排队数、路口配时周期及有效绿灯时间计算公式^[19]如下:

平均排队队长为

$$g_i(i) = \alpha_i \lambda_i \sum_{k=1}^N \gamma_k / \left(1 - \sum_{k=1}^N \rho_k\right). \quad (17)$$

定时配时公式为

$$\begin{cases} T_i = \beta_i \operatorname{argmin}(g_i(i), L_{th}), \\ C_L = \sum_{i=1}^N (\gamma_i + T_i). \end{cases} \quad (18)$$

其中: T_i 为相位 i 的有效绿灯时间, C_L 为门限服务轮询控制策略下最佳信号配时周期.

3) 控制策略匹配.

车流量分布较为离散没有规律,门限服务轮询在线配时能够对各个相位车辆状况综合考虑,可以降低车辆延误与排队队长.高峰时期道路较拥堵,采用在线配时易造成配时饱和的现象,导致控制效果不佳.根据高峰时段流量较大且具有规律性这一特点,可对交通流采用基于不同的交通流优化设计的韦伯斯特配时方案.车流量分布均匀且车流量不多时,可以将韦伯斯特配时方案优化为两相位,采取对向放行,城市中车流量较少的路口中广泛采用这种方案,利于保持道路流畅.在夜间车流量较低时,可以将交通信号灯设置为黄闪灯模式,让车辆在确保安全的情况下有序通行.通过上述分析得出对应交通流模式下的匹配策略如表3所示.

表3 5种交通流模式下的建议匹配策略

交通流类别模式	建议控制策略
F_1	黄闪灯
F_2	门限服务轮询配时
F_3, F_4, F_5	基于交通流优化韦伯斯特配时

为实现单点路口中与交通流模式匹配的自适应

交通信号控制,以平均行车延误为测评指标,对取样的路口在实测定时控制,韦伯斯特配时下的控制效果与基于交通流优化韦伯斯特配时和门限轮询配时下的控制效果进行对比,结果如表4所示.可以看到,由于门限服务轮询系统在流量高峰模式 F_5 下存在过饱和现象,基于交通流模式对相位进行优化的韦伯斯特控制策略优于门限服务轮询系统.

表4 4种配时方案对车辆平均行车延误的影响

交通流类别模式	F_2	F_3	F_5
路口实际配时	39.3	36.8	57.7
韦伯斯特配时	31.8	34.5	49.2
基于交通流优化韦伯斯特配时	24.5	21.7	28.3
门限轮询配时	19.2	23.3	30.1

2.4.2 区分交通流模式的动态匹配算法步骤

通过实地获取历史交通数据,基于SOM网络对交通流模式进行合理划分,通过测试样本检验PNN网络对交通流模式识别的准确性和快速性,由表4得出控制策略对行车延误的影响后提出了控制策略与交通流模式 F_j 的匹配表,最终建立区分交通流模式下的动态匹配算法,详细算法步骤如下.

step 1: 建立动态交通流模型.对采集到的交通数据以 15 min 为时间间隔运用极大熵原理获取交通流 OD 矩阵输入样本 $Q = (q_{13}, q_{31}, q_{14}, q_{32}, q_{42}, q_{24}, q_{43}, q_{21})$.

step 2: 交通流模式划分,将交通流 OD 矩阵样本 Q 输入 SOM 神经网络.按照第 2.2 节步骤进行训练,精细化划分出不同的交通流类别编号记为 F_j , Q_i 隶属于 F_j 类模式, i 为交通流样本数, j 为交通流类别数.

step 3: 交通流模式识别.实时统计图 1 中各个相位中路段 O_i 至路段 D_j 的车流量数据视为交通测试样本,通过第 2.3 节中 PNN 神经网络能够快速识别出路口实时交通流模式编号 F_j .

step 4: 控制策略匹配.由表 3 基于交通流模式的建议控制策略表实现交通流模式 F_j 与控制策略的匹配,根据配时公式(15)~(18)对当前交通流模式 F_j 进行信号周期时长 C 和绿灯时长 T_i 的计算,完成单点路口自适应交通信号控制.

step 5: 控制策略切换.交通流模式 F_i 发生变化或实时排队长度 L_i 与队长估计值 $g_i(i)$ 之间持续 2 个信号周期误差大于 $\pm 10\%$ 时,跳至 step 4 重新选择控制策略并更新信号周期时长 C 和绿灯时长 T_i .

3 实验分析

以昆明市景明南路与聚贤街交叉口实测交通数据为测试样本,基于 VISSIM 验证所建信号控制策

略的有效性. 采用本文所述控制算法对2018年12月30日样本路口24h内交通流模式划分及配时策略匹配. 采用动态匹配信号控制方案对道路通行状况的改进效果如图3、图4和表4所示.

1) 实际配时: 调查路口实际信号配时方案.

2) 无优化韦伯斯特配时: 在路口中采用没有根据交通流优化的独立韦伯斯特配时.

3) 文献[19]在路口中采用独立的门限服务轮询控制策略.

4) 文献[8]在路口中采用文献[8]的配时方案.

5) 本文所提算法: 本文提出的区分交通流模式的动态匹配算法.




图3 7:00~24:00时间段内车辆平均行车延误




图4 7:00~24:00时间段内车辆平均停车次数

由实验结果可以看到: 路口实际配时即固定相等配时方法效果最差, 究其原因是为了便捷设置信号而忽略了路段信息不同而造成车流量不同; 韦伯斯特配时方法基于长时间历史交通数据的信息进行周期设置与绿灯时间分配, 其效果比固定配时方法好, 但仍然不能跟随车流量的变化更改其绿灯时间, 在一定程度上减少了行车延误, 但改善效果较弱, 与实际配时相比行车延误降低了15.07%. 总体上, 与固定配时相比, 本文所提方法减少平均行车延误46.44%, 减少平均停车次数39.01%; 与韦伯斯特配时方案相比, 本文所提方法减少平均行车延误36.93%, 减少平均停车次数40.71%; 与文献[19]门限服务轮询相比, 本文所提方法减少平均行车延误9.22%, 减少平均停车次数13.85%; 与文献[8]方法相比, 本文所提方法减少平均行车延误10.81%, 减少平均停车次数14.1%.

下面对区分交通量模式的动态匹配算法控制效

果进行具体分析. 由图3和图4可以看到, 在早晚高峰(7:30~9:30, 18:00~19:30)车流量较大情况下(交通流模式 F_4 和 F_5), 实际配时方案与无优化韦伯斯特配时方案均产生较高的延误, 最高行车延误达到了59s. 而门限轮询系统在服务车流量数据时轮询系统易饱和, 容易对某一路段的车辆持续放行造成其他路段车辆停留在多个信号周期, 动态选取基于交通流的韦伯斯特配时方法, 该方案根据车流量规律设置周期与相位, 相位设置比较灵活, 可以选择为三相位、两相位或四相位, 避免了轮询过程中的饱和现象, 所以通行效果优于固定配时与门限轮询方法, 能够减少车辆通过路口的平均等待时间. 在早高峰期(7:30~9:30)内, 本文所提算法与文献[19]门限服务轮询相比, 行车延误减少了8.89%, 停车次数降低了11.65%. 停车次数受到周期长度影响较大, 且周期长度减少停车次数增加. 由于车流量跟随时间上动态变化, 在效果上存在波动性, 另外相位分配作为交通信号控制的重要一环, 应该根据历史车流量分布状态提前设计路口的相位与周期做到与车流量匹配.

在车流量稀疏(交通流模式 F_2)的时间段上(10:30~12:30, 15:00~16:30), 如10:30~12:30时间段, 与文献[8]和文献[19]方法对比, 本文所提算法分别降低行车延误15.29%和12.19%, 基于门限服务轮询方法通过了解实时车流量情况并考虑到各相位车辆权重, 为不同方向车流分配了合理的绿灯通行时间, 取得了更好的效果, 展现了门限服务轮询模型配时方案的合理性与优越性. 在交通流模式变换频率较高的时间段(10:30~12:30, 15:00~16:30, 20:30~23:30), 如10:30~12:30时间段, 交通流模式在 F_2 与 F_3 间频繁转换, 文献[8]虽然利用遗传算法对关键参数进行了优化, 但在行车延误和停车次数上均高于文献[19]中的门限服务轮询. 针对交通模式变换频率较高的时间段(20:30~23:30), 对比文献[19]和文献[8], 本文所提算法分别降低行车延误5.06%和10.58%. 门限服务轮询能够在车流量波动较大时展现出良好的适应性. 在23:30后, 路口交通模式为 F_1 , 优先匹配黄闪灯能够降低延误, 具有较大的局限性, 仅适用于车流量非常低的情况.

统计5种配时方案下车辆平均行驶速度和排队队长整体效果见表5. 本文所提算法与文献[8]对比, 平均行驶速度分别提高了11.89%, 减少排队队长27.7%. 而与文献[19]相比, 平均行驶速度分别提高了9.14%, 减少排队队长25.33%. 本文所提算法控制效果分别优于门限服务轮询和文献[8]的方法.

表5 车辆平均行驶速度和平均排队队长

控制策略	平均行驶速度	平均排队队长
实际配时	26.45	38.36
无优化韦伯斯特配时	28.63	36.72
文献[8]方法	33.82	28.59
文献[19]方法	34.67	27.68
本文算法	37.84	20.67

4 结论

本文针对独立路口讨论了交通路口中时间段及路段特征影响下的车流量分布规律,提出了区分交通流模式的混合控制策略,并通过实验验证了所提出控制方案的正确性,下一步将在以下方面进行研究:

1) 车流量分布的特征分析:通过物联网智能设备,获取更多更精确的历史交通数据,提高本文方案分析的准确性与实用性.

2) 区域交通流模式分析:本文实验中的交通路口仅有一个,特征规律把握较为准确,对于区域交通路口,将进一步研究大规模路口下的交通流模式.

参考文献(References)

[1] 闫飞, 田福礼, 史忠科. 城市区域交通信号迭代学习控制策略[J]. 控制与决策, 2015, 30(8): 1411-1416.
(Yan F, Tian F L, Shi Z K. Iterative learning control strategy for traffic signal of urban area[J]. Control and Decision, 2015, 30(8): 1411-1416.)

[2] Xu C C, Liu P, Wang W, et al. Evaluation of the impacts of traffic states on crash risks on freeways[J]. Accident: Analysis & Prevention, 2012, 47(1): 162-171.

[3] Wang L L, Ngan H Y T, Yung N H C. Automatic incident classification for large-scale traffic data by adaptive boosting SVM[J]. Information Sciences, 2018, 467: 59-73.

[4] Zheng F F, Zuylen H V, Liu X B, et al. Reliability-based traffic signal control for urban arterial roads[J]. IEEE Transactions on Intelligent Transportation Systems, 2017: 18(3): 643-655.

[5] Kouvelas A, Aboudolas K, Papageorgiou M, et al. A hybrid strategy for real-time traffic signal control of urban road networks[J]. IEEE Transactions on Intelligent Transportation Systems, 2011, 12(3): 884-894.

[6] Boon M A A, Adan I J B F, Winands E M M, et al. Delay at signalized intersections with exhaustive traffic control[J]. Probability in the Engineering and Informational Sciences, 2012, 26(3): 337-373.

[7] Li L, Lv Y S, Wang F Y. Traffic signal timing via deep reinforcement learning[J]. IEEE/CAA Journal of Automatica Sinica, 2016, 3(3): 247-254.

[8] Yun I, Park B. Stochastic optimization for coordinated actuated traffic signal systems[J]. Journal of Transportation Engineering, 2012, 138(7): 819-829.

[9] 齐驰, 侯忠生, 贾琰. 基于排队长度均衡的交叉口信号配时优化策略[J]. 控制与决策, 2012, 27(8): 1191-1194.

(Qi C, Hou Z S, Jia Y. Optimal signal timing strategy based on the equilibrium of queue length[J]. Control and Decision, 2012, 27(8): 1191-1194.)

[10] Barreto G A, Araujo A F R. Identification and control of dynamical systems using the self-organizing map[J]. IEEE Transactions on Neural Networks, 2004, 15(5): 1244-1259.

[11] Bachoc C, Vallentin F. Optimality and uniqueness of the (4, 10, 1/6) spherical code[J]. Journal of Combinatorial Theory, 2009, 116(1): 195-204.

[12] Fan D K, Luo X Q, Chen K M. Verification method of resident trip OD matrix based on screen area [J]. Journal of Traffic and Transportation Engineering, 2009(6): 121-126.

[13] Wang X D, Cottrell W, Mu S C. Using *k*-means clustering to identify time-of-day break points for traffic signal timing plans[C]. Proceedings of the 2005 IEEE Intelligent Transportation Systems. Vienna: IEEE, 2005: 586-591.

[14] 杨立才, 贾磊, 孔庆杰, 等. 基于人工免疫算法的交通时段自动划分方法[J]. 控制理论与应用, 2006, 23(2): 35-40.
(Yang L C, Jia L, Kong Q J, et al. Method of automatic programming traffic intervals based on artificial immune algorithm[J]. Control Theory & Applications, 2006, 23(2): 35-40.)

[15] Kim Jiwon, Mahmassani H S. Spatial and temporal characterization of travel patterns in a traffic network using vehicle trajectories[J]. Transportation Research Procedia, 2015, 59: 164-184.

[16] Ghosh A, Pal S K. Neural network, self-organization and object extraction[J]. Pattern Recognition Letters, 1992, 13(5): 387-397.

[17] Specht D F. Probabilistic neural networks[J]. Neural Networks, 1990, 3(1): 109-118.

[18] Ohno K, Mine H. Optimal traffic signal settings: A refinement of Webster's method[J]. Transportation Research, 1973, 7(3): 269-292.

[19] 官铮, 何敏, 钱文华. 基于车辆驱动的交通灯控制策略及仿真研究[J]. 系统仿真学报, 2014, 26(11): 2607-2611.
(Guan Z, He M, Qian W H. Vehicle-actuated traffic signal control scheme and its simulation study[J]. Journal of System Simulation, 2014, 26(11): 2607-2611.)

作者简介

童林(1995—), 男, 硕士生, 从事智能控制的研究, E-mail: tonglin0123@foxmail.com;

官铮(1982—), 女, 副教授, 博士, 从事无线网络通信技术、智能交通控制、切换服务系统及应用等研究, E-mail: gz_627@sina.com;

杨文韬(1976—), 男, 副教授, 博士, 从事激光器、光电传感器及应用等研究, E-mail: youngwentao@163.com;

祝昆(1976—), 男, 教授, 博士, 从事激光器、光电传感技术等研究, E-mail: lpszck@163.com.