

# 基于虚拟动态检测的自适应信号控制方法

蒋贤才, 邢 令

(东北林业大学 土木与交通学院, 哈尔滨 150040)

**摘要:** 鉴于传统固定检测方法难以获取连续动态车辆信息的限制, 提出一种非完全网联交通环境下基于虚拟动态检测的交叉口自适应信号控制方法(ACV2D方法), 以解决信号控制精度不高的问题。通过ACV2D方法构建了一个位置可变的虚拟检测断面和区间来替代传统交通流检测器, 每个信号相位取得通行权后, 以排队车辆中最远网联车(CV)所在位置为依据测算初始绿灯时间, 同时利用测得的CV信息来预测虚拟检测断面和区间内交通流状况和绿灯持续时间, 在此过程中监视虚拟检测区内交通流状况与预测结果的一致性。当预测结果出现偏差时, 以车均延误最小为优化目标, 构建信号控制参数的实时修正模型, 并以预测的车辆到达时间为决策点, 采取动态规划法以信号相位为阶段正序求解最佳信号相位配时。仿真结果表明, 当CV渗透率大于50%时, ACV2D方法在中高流量下的实施效果明显优于基于强化学习的自适应信号控制方法(3DQN和3DRQN方法)。进一步研究表明, ACV2D方法的控制成效受CV渗透率和关键车道组流率比之和( $Y$ ) 2个因素的共同影响;  $Y$  值越大, 确保ACV2D方法有效的CV渗透率要求就越低, 反之亦然。

**关键词:** 交通工程; 智能交通; 自适应信号控制; 动态规划法; 虚拟检测; 非完全网联交通环境

中图分类号: U491

文献标志码: A

## Adaptive Signal Control Method Based on Virtual Dynamic Detection

JIANG Xiancai, XING Ling

(School of Civil Engineering and Transportation, Northeast Forestry University, Harbin 150040, China)

**Abstract:** Given the limitations of traditional fixed detection methods in capturing continuous and dynamic vehicle information, we propose an adaptive signal control method (ACV2D method) based on virtual dynamic detection for intersections in a partially connected traffic environment to address the issue of low signal control accuracy. Through the ACV2D method, the position-variable virtual detection section and interval are

built to replace conventional traffic flow detectors. After a signal phase gains the right of way, the initial green time is calculated based on the position of the farthest connected vehicle (CV) in the queue. Simultaneously, the measured CV data are used to predict traffic flow conditions within the virtual detection section and interval, as well as the duration of phase green time. During this process, the consistency between the predicted and actual traffic flow conditions within the virtual detection area is monitored. When the prediction results deviate, a real-time correction model for signal control parameters is constructed with the objective of minimizing the average vehicle delay. Taking the predicted vehicle arrival time as the decision point, the dynamic programming method is adopted to solve the optimal signal phase timing in a forward sequence of signal phases. Simulation results demonstrate that when the CV penetration rate exceeds 50%, ACV2D method significantly outperforms reinforcement learning-based adaptive signal control methods, such as 3DQN and 3DRQN, under medium to high traffic volumes. Further research indicates that the effectiveness of the ACV2D method is jointly influenced by two factors, i. e., CV penetration rate and the sum of key lane group flow ratios  $Y$ . The larger the  $Y$  value, the lower the required CV penetration rate to ensure the effectiveness of the ACV2D method; conversely, the smaller the  $Y$  value, the higher the required CV penetration rate.

**Keywords:** traffic engineering; intelligent transportation; adaptive signal control; dynamic programming method; virtual detection; partially connected traffic environment

交叉口作为城市交通网络中的关键节点, 其运行效率的高低直接影响整个交通系统的通畅与否。

收稿日期: 2024-11-29

基金项目: 黑龙江省自然科学基金(PL2024E012)

第一作者: 蒋贤才, 教授, 工学博士, 主要研究方向为智能交通系统、道路交通安全。E-mail: jxc023@nefu.edu.cn



论文  
拓展  
介绍

持续完善交叉口信号控制方法,对提升交叉口运行效率、减少交通拥堵和环境污染,具有重要的现实意义和理论价值。作为一种高阶的智能优化算法,自适应信号控制能够根据检测到的交通流状态决策最优信号相位转换时间节点,因此其一直是信号控制领域的研究热点。

当前,自适应信号控制研究主要聚焦于以下2个方面:

(1) 模型驱动的自适应信号控制方法。基于现代控制理论的自适应信号控制方法统称为模型驱动方法(model based control, MBC)。模型驱动的自适应信号控制假设车辆的运动规律符合建立的预测模型,并在此基础上求解最优控制方法。该类方法多依赖于交通流预测,现有研究也多集中于优化预测模型。Duan等<sup>[1]</sup>将灰色预测模型GM(1,1)与Tucker张量分解最小二乘法相结合,建立了张量交替最小二乘灰色预测模型。Cai等<sup>[2]</sup>利用最大熵准则优化卡尔曼滤波,得到基于噪声免疫卡尔曼滤波的交通流预测(noise-immune Kalman filter for traffic flow forecasting, NIKF)。Yang等<sup>[3]</sup>提出一种基于出行时间转移模型的拉格朗日空间卡尔曼滤波交通状态估计模型。此外,还有部分学者通过建立分级或分层的MBC来实施优化控制<sup>[4-6]</sup>。然而,该类方法高度依赖模型精度,当系统面临复杂的非线性、时变或未知的外部扰动时,算法精度难以得到保障。

(2) 数据驱动的自适应信号控制方法。数据驱动的自适应信号控制是指利用实时或历史交通数据,通过数据分析、机器学习等方法,自动调整交通信号灯的配时方案。数据驱动的自适应信号控制不需要复杂建模也能取得较好的控制效果,是当前信号控制领域的研究热点。Hong等<sup>[7]</sup>对一种多模型神经网络进行建模,并利用在线学习寻求最优自适应信号控制方案。刘佳佳等<sup>[8]</sup>利用遗传算法优化模糊控制规则和隶属度函数,实现了对绿灯延长时间的精准决策。Touhbi等<sup>[9]</sup>利用微型交通模拟器Paramics开发了一种多相位交叉口强化学习控制方法,验证了强化学习特别是Q学习在信号控制中的优势。Liang等<sup>[10]</sup>将交叉口划分为网格量化交通状态,采用延误作为奖励构建模型,仿真验证了模型的有效性。陆丽萍等<sup>[11]</sup>以深度Q网络为基本框架,提出了交叉口信号优化控制的3DRQN(dueling double deep recurrent Q network)算法,并证实了该算法的优异控制效果和鲁棒性。郭海锋等<sup>[12]</sup>使用无模型控制方法预测交通流变化,以此优化信号参数,制定交叉口交通状态信号周期模板,并实现了排队长度的均衡。Wang等<sup>[13]</sup>则利用无模型控制方法解决了多智能体系统的容

错共识跟踪控制问题。虽然数据驱动的自适应信号控制方法在无法完全获取交通信息、无法完全理解系统内部机理或不能准确预测交通流状况的情况下具有独特优势,但是其本身需要较长训练周期、较多车辆检测器,且对数据具有高度依赖性,可移植性差。此外,为确保算法实时性,数据驱动的自适应信号控制算法往往采用固定步长来延长绿灯时间,只能决策车辆是否被放行,而无法确定该车辆何时通过交叉口,算法控制精度有限。

近年来,随着网联技术的兴起,全面获取道路上的实时交通状况成为可能,为自适应信号优化控制开启了新的研究思路。Lin等<sup>[14]</sup>将基于网联车(connected vehicle, CV)采集数据的自适应信号控制与基于传统检测的基本信号控制进行比较。结果表明,自适应信号控制最多可降低91%的总碰撞风险、71%的交叉碰撞风险、90%的追尾碰撞风险和100%的变道碰撞风险。同时,提高了6.80%的吞吐量,降低了91.49%的平均延迟、96.23%的队列长度和75.00%的停止次数。此外,将CV数据应用于信号控制来减少延误、提升交叉口通行效率的研究也十分常见<sup>[15-17]</sup>。这些研究证实, CV可作为移动检测代替固定检测,且数据采集的全面性和实时性是传统交通流检测器无法企及的。

本文以CVs和人类驾驶车(human-driven vehicles, HVs)混行的非完全网联交通为背景,利用CVs轨迹实时可测的优势来探测HVs的运行,进而提出基于虚拟动态检测的自适应信号控制方法(ACV2D方法),以期提升非完全网联交通环境下的信号控制成效。

## 1 问题描述

为提升自适应信号控制精度,本文提出虚拟检测概念。虚拟检测是指在道路某一断面、某一区间内设置虚拟检测点位,利用行驶至此的CVs状态来采集交通信息的一种检测方式。通过CVs轨迹的异常变化探测HVs的运行,虚拟检测位置可根据需要设置并承担不同的作用。

虚拟检测断面主要为信号控制提供预检测能力。如图1所示,不设虚拟检测断面时,假设 $t_1$ 时刻目标车辆(即当前信号相位能放行的距停车线最近的CV)实际运行轨迹与预测轨迹完全一致并通过停车线,需要在 $t_3$ 时刻通过执行优化程序决策新的信号控制方案,此时方法实时性难以保证且优化过程中信号控制方案空耗。设置虚拟检测断面后, $t_2$ 时




图 1 虚拟检测断面 workflow 示意

Fig.1 Schematic diagram of virtual detection section workflow

刻目标车辆通过虚拟检测断面并在  $t_0$  后抵达目标位置(停车线);在  $t_2$  时刻执行优化程序,生成新的信号控制方案以在  $t_3$  时刻启用,从而保证优化的实时性。图 1 中,  $t_1$  为上一决策时刻,  $t_2$  为设置虚拟检测断面时目标车辆通过虚拟检测断面的时刻,  $t_3$  为目标车辆通过目标位置的时刻,  $l_{vds}$  为虚拟检测断面位置。虚拟检测断面位置为

$$l_{vds} = v_{os}t_0 \quad (1)$$

式中:  $v_{os}$  为目标车辆  $t_3$  时刻速度;  $t_0$  为预检测的提前时间长度。

最佳信号控制方案求解多依赖于预测车辆的到达时间,而车辆的实际轨迹与预测结果会存在差异。为此,执行已有信号控制方案时,需通过车辆实际运行轨迹与预测轨迹的差异来修正信号控制参数。本

文设立虚拟检测区间以辅助检测车辆实际位置与目标位置的符合度,作为判断信号控制方案是否调整的依据。如图 2 中  $S_1$  所示,不设虚拟检测区间时,执行完上一次决策的信号控制方案后,若目标车辆未能到达目标位置但接近目标位置,则难以判断该信号控制方案能否继续使用。根据方案允许的误差范围设置虚拟检测区间后,如图 2 中  $S_2$  所示,目标车辆位于虚拟检测区间内,以此判断可继续沿用该方案;若目标车辆不在虚拟检测区间内时(即图 2 中  $S_3$  对应的情况),则表示当前方案不符合实际情况,需提前修正该信号控制方案。虚拟检测区间长度设置为

$$l_{vdr} = \epsilon l_{vds} \quad (2)$$

式中:  $l_{vdr}$  为虚拟检测区间长度;  $\epsilon$  为可接受误差范围。




图 2 虚拟检测区间 workflow 示意

Fig.2 Schematic diagram of virtual detection interval workflow

结合动态规划方法,本文构建的 ACV2D 方法流程见图 3。图 3 中,  $t_{pass}(i)$  为第  $i$  辆 CV 通过交叉

口的时间,  $t_{enter}(i)$  为第  $i$  辆 CV 进入交叉口的时间,  $t_d$  为所有 CV 在交叉口的总行驶时间。

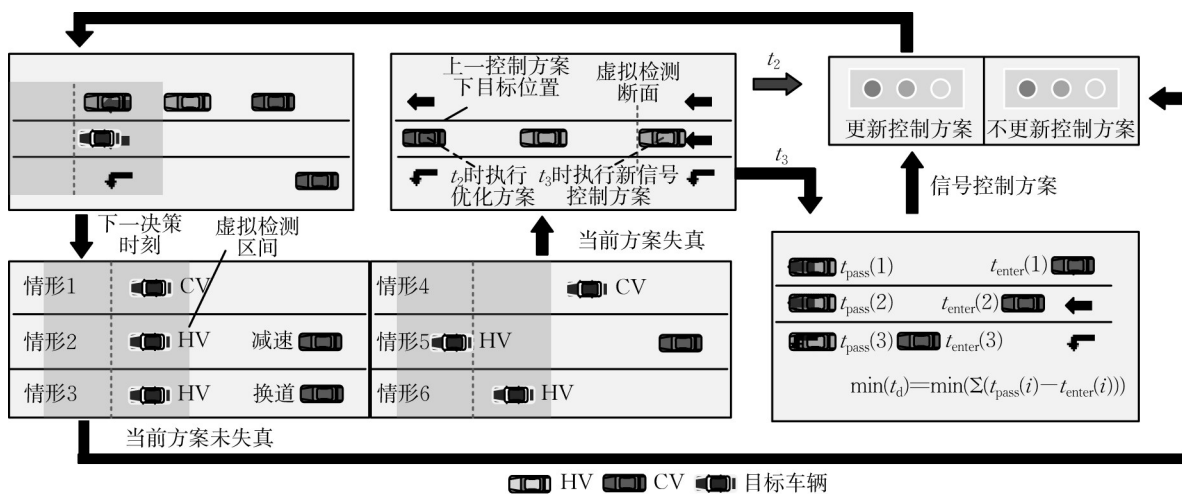


图 3 ACV2D 方法流程示意

Fig.3 Schematic diagram of ACV2D method

ACV2D方法利用CVs返回信息获取各车道的交通状态,预测车辆到达虚拟检测断面及区间的时间,并以延误最小为优化目标、采取非固定步长的方式决策最佳信号控制方案。在执行各信号相位控制方案过程中,结合虚拟检测断面、虚拟检测区间和CVs实时信息,提前判断实际交通状况与预测交通状况是否一致,以决定沿用或修正信号相位的控制方案。当目标车辆为CV时,车辆信息可直接获取,若CV位于虚拟检测区间内(即情形1),则表明目标车辆仍在方案的控制范围内,控制方案可继续使用;若目标车辆CV位于虚拟检测区间外(即情形4),则表明目标车辆不在方案的控制范围内,预测轨迹已偏离,当前控制方案需要修正。当目标车辆为HV时,车辆具体位置无法被直接检测到,但其后方存在CV且该CV有明显的减速行为(即情形

2)或换道行为(即情形3),则表明目标车辆仍在当前方案的控制范围内;若其后方不存在CV(即情形6)或存在CV但CV没有减速或变道行为(即情形5),则目标车辆无法被观测到,难以界定其是否在方案的控制范围内,此时认为该控制方案失真且无法继续沿用,需修正控制方案。

## 2 优化方法

### 2.1 优化目标

开始执行优化程序生成的控制方案至 $t_{m,\alpha}$ 时,交叉口车辆总延误的增长量包括放行车辆的正向收益和其他相位车辆延误增加的负向收益。优化目标是使执行方案带来的总效益最大,即:

$$W = \max \left[ \omega(t_{m,\text{begin}}) + \sum_{\alpha=1}^{\alpha_{\max}} \omega(t_{m,\alpha}) + \omega(t_{m,\text{end}}) \right], \forall x_{m,n,i}(t_{m,\alpha-1})x_{m,n,i}(t_{m,\alpha}) < 0 \text{ 或 } \forall \min \{ a_{m,n,i}(t_{m,\alpha}), [x_{m,n,i}(t_{m,\alpha}) - h_{m,n,i}(t_{m,\alpha})][x_{m,n,i}(t_{m,\alpha-1}) - h_{m,n,i}(t_{m,\alpha-1})], x_{m,n,i-1}(t_{m,\alpha}) + s_0 - x_{m,n,i}(t_{m,\alpha}) + h_{m,n,i}(t_{m,\alpha}) \} < 0 \quad (3)$$

$$\omega(t_{m,\alpha}) = n_p(t_{m,\alpha})E(c) - \sum_{m=1}^{m_{\max}} \sum_{n=1}^{n_{\max}} [l_{m,n}(t_{m,\text{begin}}) | s_{m,n}(t_{m,\alpha}) - 1 | (t_{m,\alpha} - t_{m,\alpha-1}) / \bar{h}_s] \quad (4)$$

式中: $\omega(t_{m,\alpha})$ 为绿灯由 $t_{m,\alpha-1}$ 时刻执行至 $t_{m,\alpha}$ 时刻的收益; $t_{m,\text{begin}}$ 为相位 $m$ 的绿灯开启时刻; $t_{m,\alpha}$ 为相位 $m$ 绿灯开启后第 $\alpha$ 个有车辆通过的时刻; $\alpha_{\max}$ 为相位 $m$ 绿灯开启后最后一个有车辆通过的时刻; $t_{m,\text{end}}$ 为相位 $m$ 的绿灯结束时刻; $x_{m,n,i}(t_{m,\alpha})$ 为相位 $m$ 车道 $n$ 上 $t_{m,\alpha}$ 时刻第 $i$ 辆CV距离停车线的位置预测值; $a_{m,n,i}(t_{m,\alpha})$ 为相位 $m$ 车道 $n$ 上 $t_{m,\alpha}$ 时刻第 $i$ 辆CV的加速度预测值; $h_{m,n,i}(t_{m,\alpha})$ 为相位 $m$ 车道 $n$ 上 $t_{m,\alpha}$ 时刻第 $i$ 辆CV与前车的车头间距预测值; $s_0$ 为最小安全间距,根据已有相关研究取值为 $2 \text{ m}^{[18]}$ ; $n_p(t_{m,\alpha})$ 为当前绿灯延长方案下绿灯由 $t_{m,\alpha-1}$ 执行至 $t_{m,\alpha}$ 预测额外放行的车辆数; $m_{\max}$ 为当前交叉口的相位数量; $n_{\max}$ 为当前交叉口的车道数量; $E(c)$ 为当前信号动作及交

通流状况下的期望周期; $l_{m,n}(t_{m,\text{begin}})$ 为相位 $m$ 车道 $n$ 上 $t_{m,\text{begin}}$ 时刻的最远CV所在位置; $s_{m,n}(t_{m,\alpha})$ 为相位 $m$ 车道 $n$ 上 $t_{m,\alpha}$ 时刻的灯色状况,为1表示绿灯,为0表示红灯或黄灯; $\bar{h}_s$ 为平均车头间距。

### 2.2 车辆信息预测

由于上述优化程序执行时输入变量只有优化开始时刻车辆的速度、位置、加速度信息,因此需要对未来车辆的信息进行预测。预测方法如下:

$$x_{m,n,i}(t_{m,\alpha}) = x_{m,n,i}(t_{m,\alpha-1}) + [v_{m,n,i}(t_{m,\alpha-1}) + v_{m,n,i}(t_{m,\alpha})](t_{m,\alpha} - t_{m,\alpha-1})/2 \quad (5)$$

$$v_{m,n,i}(t_{m,\alpha}) = v_{m,n,i}(t_{m,\alpha-1}) + [a_{m,n,i}(t_{m,\alpha-1}) + a_{m,n,i}(t_{m,\alpha})](t_{m,\alpha} - t_{m,\alpha-1})/2 \quad (6)$$

$$a_{m,n,i}(t_{m,\alpha}) = \begin{cases} k_1 [x_{m,n,i-1}(t_{m,\alpha-1}) - x_{m,n,i}(t_{m,\alpha-1}) - T_c v_{m,n,i}(t_{m,\alpha-1}) - l - s_0] + k_2 [v_{m,n,i-1}(t_{m,\alpha-1}) - v_{m,n,i}(t_{m,\alpha-1})], \\ \quad i > 1 \text{ 或 } i = 1, s_{m,n}(t_{m,\alpha-1}) = 1 \\ k_1 [-x_{m,n,i}(t_{m,\alpha-1}) - T_c v_{m,n,i}(t_{m,\alpha-1}) - l - s_0] + k_2 [-v_{m,n,i}(t_{m,\alpha-1})], i = 1, s_{m,n}(t_{m,\alpha-1}) = 0 \end{cases} \quad (7)$$

式中: $v_{m,n,i}(t_{m,\alpha})$ 为相位 $m$ 车道 $n$ 上 $t_{m,\alpha}$ 时刻第 $i$ 辆CV的速度预测值; $k_1, k_2$ 为控制系数; $T_c$ 为自适应巡航控制跟驰模型期望保持的恒定车间时距; $l$ 为车长。模型参数取值为 $^{[18-19]}$ : $k_1=0.25, k_2=0.02, T_c=1.5 \text{ s}$ 。

在车辆位置预测的基础上,当前绿灯延长方案下

绿灯由 $t_{m,\alpha-1}$ 执行至 $t_{m,\alpha}$ 时额外放行的预测车辆数为:

$$n_p(t_{m,\alpha}) = \sum_{m=1}^{m_{\max}} \sum_{n=1}^{n_{\max}} \sum_{i=1}^{q_{\max}} \beta_{m,n,i}(t_{m,\alpha}) + \sum_{m=1}^{m_{\max}} \sum_{n=1}^{n_{\max}} \sum_{i=1}^{q_{\max}} \chi_{m,n,i}(t_{m,\alpha}) \quad (8)$$

$$\beta_{m,n,i}(t_{m,\alpha}) = \begin{cases} 1, [x_{m,n,i}(t_{m,\alpha}) - l_{\text{vds}}][x_{m,n,i}(t_{m,\alpha-1}) - l_{\text{vds}}] < 0 \\ 0, [x_{m,n,i}(t_{m,\alpha}) - l_{\text{vds}}][x_{m,n,i}(t_{m,\alpha-1}) - l_{\text{vds}}] \geq 0 \end{cases} \quad (9)$$

$$\chi_{m,n,i}(t_{m,\alpha}) = \begin{cases} 1, \min \{ [x_{m,n,i}(t_{m,\alpha}) - h_{m,n,i}(t_{m,\alpha}) - l_{\text{vds}}][x_{m,n,i}(t_{m,\alpha-1}) - h_{m,n,i}(t_{m,\alpha-1}) - l_{\text{vds}}], \\ x_{m,n,i-1}(t_{m,\alpha}) + s_0 - x_{m,n,i}(t_{m,\alpha}) + h_{m,n,i}(t_{m,\alpha}), a_{m,n,i}(t_{m,\alpha}) \} < 0 \\ 0, \min \{ [x_{m,n,i}(t_{m,\alpha}) - h_{m,n,i}(t_{m,\alpha}) - l_{\text{vds}}][x_{m,n,i}(t_{m,\alpha-1}) - h_{m,n,i}(t_{m,\alpha-1}) - l_{\text{vds}}], \\ x_{m,n,i-1}(t_{m,\alpha}) + s_0 - x_{m,n,i}(t_{m,\alpha}) + h_{m,n,i}(t_{m,\alpha}), a_{m,n,i}(t_{m,\alpha}) \} \geq 0 \end{cases} \quad (10)$$

$$h_{m,n,i}(t_{m,\alpha}) = \{ a_{m,n,i}(t_{m,\alpha}) - k_1 [x_{m,n,i}(t_{m,\alpha}) - x_{m,n,i}(t_{m,\alpha-1})] \} / k_2 + s_0 + T_c v_{m,n,i}(t_{m,\alpha}) + l \quad (11)$$

式中:  $q_{\text{max}}$  为相位  $m$  车道  $n$  上的 CV 总数;  $\beta_{m,n,i}(t_{m,\alpha})$  为绿灯执行至  $t_{m,\alpha}$  时相位  $m$  车道  $n$  上第  $i$  辆 CV 通过交叉口的情况, 为 1 时表示可以通过, 为 0 时表示无法通过;  $\chi_{m,n,i}(t_{m,\alpha})$  为绿灯执行至  $t_{m,\alpha}$  时相位  $m$  车道  $n$  上第  $i$  辆 CV 前存在 HV 下 HV 通过交叉口的情况, 为 1 时表示可以通过, 为 0 时表示无法通过。

### 2.3 期望周期计算

计算控制动作正向收益时需要计算当前控制动作下一个周期的期望周期时长。此时, 其他相位绿灯时间尚未决策, 后续相位无法进行绿灯延长的收益计算。在不进行放行收益计算时, 本文方法可以近似看作感应信号控制方法。为计算期望周期, 在执行完初始绿灯时间时以感应控制方法基本原理计算期望绿灯延长时间。假设后续车辆服从泊松分布, 则感应控制检测断面到达第  $n$  辆车的概率为

$$P(N_{m+\Delta m}) = \frac{[R/\overline{h_{m+\Delta m}}(t_{m,\alpha})]^{N_{m+\Delta m}}}{N_{m+\Delta m}!} e^{-R/\overline{h_{m+\Delta m}}(t_{m,\alpha})} \quad (12)$$

式中:  $P(N_{m+\Delta m})$  为相位  $(m+\Delta m)$  感应控制检测断面到达  $n$  辆车的概率,  $\Delta m \in \{1, 2, 3, \dots\}$ ;  $R$  为控制范围半径;  $\overline{h_{m+\Delta m}}(t_{m,\alpha})$  为相位  $(m+\Delta m)$  在  $t_{m,\alpha}$  时刻所有车辆的平均车头间距;  $N_{m+\Delta m}$  为相位  $(m+\Delta m)$  感应控制检测断面到达的车辆数。各相位期望绿灯延长时间为

$$E(G_{\Delta m}) = R/\overline{h_{m+\Delta m}}(t_{m,\alpha}) \Delta g \quad (13)$$

式中,  $\Delta g$  为单位绿灯延长时间。

由式(13)可知, 不论单位绿灯延长时间取值为多少, 各相位绿灯延长时间与平均车头间距成反比, 则期望周期时长计算式为:

$$E(c) = \sum_{\Delta m=0}^3 E(G_{\Delta m}) \quad (14)$$

$$\begin{cases} E(G_{\Delta m}) = g_f \{ L_{m+\Delta m} [E(G_{\Delta m-1})] \} + \\ \overline{h_m}(t_{m,\alpha}) \max(U_{t_{m,\alpha}}) / \overline{h_{m+\Delta m}}(t_{m,\alpha}) \\ E(G_0) = t_{m,\alpha} - t_{m,\text{begin}} \end{cases} \quad (15)$$

$$g_f(x) = \begin{cases} t_r + \frac{x}{v_w} + \frac{(x - v_c^2/2a)}{v_c} + \frac{v_c}{a}, x \geq \frac{v_c^2}{2a} \\ t_r + \frac{x}{v_w} + \left(\frac{2x}{a}\right)^{\frac{1}{2}}, x < \frac{v_c^2}{2a} \end{cases} \quad (16)$$

$$\begin{cases} \overline{h_m}(t_{m,\alpha}) = \sum_{n=1}^{n_{\text{max}}} \sum_{i=1}^{q_{\text{max}}} \frac{x_{m,n,i}(t_{m,\alpha}) - x_{m,n,i-1}(t_{m,\alpha})}{v_{m,n,i}(t_{m,\alpha})} \\ x_{m,n,0}(t_{m,\alpha}) = 0 \end{cases} \quad (17)$$

$$U_{t_{m,\alpha}} = [u_{1,1}(t_{m,\alpha}), \dots, u_{m,n}(t_{m,\alpha})] \quad (18)$$

式中:  $E(G_j)$  为当前相位之后第  $j$  相位的期望绿灯时间;  $L_m(t)$  为相位  $m$  在  $t$  时刻最远排队 CV 位置;  $g_f(x)$  为当排队长度  $x$  时清空所需要的时间;  $U_{t_{m,\alpha}}$  为  $t_{m,\alpha}$  时刻交叉口各车道的灯色变化情况向量, 1 代表灯色变化, 0 表示保持不变;  $t_r$  为驾驶员反应时间;  $v_w$  为启动波传递速度;  $v_c$  为车辆通过交叉口的期望速度;  $a$  为对应车辆的加速度;  $u_{m,n}(t_{m,\alpha})$  为相位  $m$  车道  $n$  在  $t_{m,\alpha}$  时刻灯色变化情况, 1 代表灯色变化, 0 表示保持不变。

### 2.4 约束条件

#### 2.4.1 初始绿灯时间约束

ACV2D 方法需要执行预检测以保证算法实时性, 因此在不考虑行人过街情况下, 初始绿灯时间应不低于提前检测时刻; 同时, 为避免二次停车的发生, 初始绿灯时间应满足初始排队长度的放行时间。初始绿灯时间约束为

$$t_{m,\text{end}} - t_{m,\text{begin}} > \max \{ t_0, g_f [L_m(t_{m,\text{begin}})] \} \quad (19)$$

#### 2.4.2 最大绿灯时间约束

本文优化方法虽与基于马尔科夫决策的 3DQN 算法<sup>[11]</sup>有所不同, 但信号控制基本原理相同, 都是在绿灯时间基础上进行延长。参考文献[11]中将最大绿灯时间设置为 60 s, 则

$$t_{m,\text{end}} - t_{m,\text{begin}} \leq 60 \quad (20)$$

## 2.5 优化方案验证方法

ACV2D方法为非完全网联交通环境下的自适应信号控制方法。HVs的存在导致预测模型精度有限,因此实际车辆运行状态与预测模型之间存在偏差。为保证控制效果,在执行控制方案时,ACV2D方法需生成当前控制方案对应的检测方案矩阵。执

行过程中,达到时间节点时,需要判断当前控制方案能否继续使用,若不能,则重新执行优化程序更新控制方案以保证算法有效性。执行至 $t_{m,\alpha}$ 时,当前控制方案的检测方案矩阵为

$$D(t_{m,\alpha}) = \begin{bmatrix} t_{m,\text{begin}} & \cdots & t_{m,\alpha} \\ 0 & \cdots & \sigma_{t_{m,\alpha}} \end{bmatrix} \quad (21)$$

$$\sigma_{t_{m,\alpha}} = \begin{cases} 1, & \sum_{m=1}^{m_{\max}} \sum_{n=1}^{n_{\max}} \sum_{i=1}^{q_{\max}} [\phi_{m,n,i}(t_{m,\alpha}) + \varphi_{m,n,i}(t_{m,\alpha})] \neq \sum_{m=1}^{m_{\max}} \sum_{n=1}^{n_{\max}} \sum_{i=1}^{q_{\max}} [\beta_{m,n,i}(t_{m,\alpha}) + \chi_{m,n,i}(t_{m,\alpha})] \\ 0, & \sum_{m=1}^{m_{\max}} \sum_{n=1}^{n_{\max}} \sum_{i=1}^{q_{\max}} [\phi_{m,n,i}(t_{m,\alpha}) + \varphi_{m,n,i}(t_{m,\alpha})] = \sum_{m=1}^{m_{\max}} \sum_{n=1}^{n_{\max}} \sum_{i=1}^{q_{\max}} [\beta_{m,n,i}(t_{m,\alpha}) + \chi_{m,n,i}(t_{m,\alpha})] \end{cases} \quad (22)$$

$$\phi_{m,n,i}(t_{m,\alpha}) = \begin{cases} 1, & [x'_{m,n,i}(t_{m,\alpha}) - l_{\text{vds}} + l_{\text{vdr}}/2][x'_{m,n,i}(t_{m,\alpha}) - l_{\text{vds}} - l_{\text{vdr}}/2] \leq 0 \\ 0, & [x'_{m,n,i}(t_{m,\alpha}) - l_{\text{vds}} + l_{\text{vdr}}/2][x'_{m,n,i}(t_{m,\alpha}) - l_{\text{vds}} - l_{\text{vdr}}/2] > 0 \end{cases} \quad (23)$$

$$\varphi_{m,n,i}(t_{m,\alpha}) = \begin{cases} 1, & \min \{ a'_{m,n,i}(t_{m,\alpha}), [x'_{m,n,i}(t_{m,\alpha}) - h'_{m,n,i}(t_{m,\alpha}) - l_{\text{vds}} + l_{\text{vdr}}/2][x'_{m,n,i}(t_{m,\alpha-1}) - h'_{m,n,i}(t_{m,\alpha-1}) - l_{\text{vds}} - l_{\text{vdr}}/2], \\ & x'_{m,n,i-1}(t_{m,\alpha}) + s_0 - x'_{m,n,i}(t_{m,\alpha}) + h'_{m,n,i}(t_{m,\alpha}) \} < 0 \\ 0, & \min \{ a'_{m,n,i}(t_{m,\alpha}), [x'_{m,n,i}(t_{m,\alpha}) - h'_{m,n,i}(t_{m,\alpha}) - l_{\text{vds}} + l_{\text{vdr}}/2][x'_{m,n,i}(t_{m,\alpha-1}) - h'_{m,n,i}(t_{m,\alpha-1}) - l_{\text{vds}} - l_{\text{vdr}}/2], \\ & x'_{m,n,i-1}(t_{m,\alpha}) + s_0 - x'_{m,n,i}(t_{m,\alpha}) + h'_{m,n,i}(t_{m,\alpha}) \} \geq 0 \end{cases} \quad (24)$$

式中: $D(t_{m,\alpha})$ 为 $t_{m,\alpha}$ 时刻当前控制方案的检测方案矩阵,第1行为检测时间点,第2行为检测结果,为1时表示需在第1行相应时间点执行优化程序并于 $t_0$ 后执行,为0时表示方案可以沿用; $\sigma_{t_{m,\alpha}}$ 为 $t_{m,\alpha}$ 时刻程序重新执行决策变量,1表示重新执行,0表示无须重新执行; $\phi_{m,n,i}(t_{m,\alpha})$ 为绿灯执行至 $t_{m,\alpha}$ 时相位 $m$ 车道 $n$ 上第 $i$ 辆CV在虚拟检测区间内的情况,1表示在虚拟检测区间内,0表示不在虚拟检测区间内; $\varphi_{m,n,i}(t_{m,\alpha})$ 为绿灯执行至 $t_{m,\alpha}$ 时刻相位 $m$ 车道 $n$ 上第 $i$ 辆CV前的HV在虚拟检测区间内的情况,1表示在虚拟检测区间内,0表示不在虚拟检测区间内; $x'_{m,n,i}(t_{m,\alpha})$ 为相位 $m$ 车道 $n$ 上第 $i$ 辆CV在 $t_{m,\alpha}$ 时刻的位置观测值; $a'_{m,n,i}(t_{m,\alpha})$ 为相位 $m$ 车道 $n$ 上第 $i$ 辆CV在 $t_{m,\alpha}$ 时刻的加速度观测值; $h'_{m,n,i}(t_{m,\alpha})$ 为相位 $m$ 车道 $n$ 上 $t_{m,\alpha}$ 时刻第 $i$ 辆CV与前车的车头间距观测值。

## 2.6 求解算法

交通信号控制中各个相位的绿灯时间决策问题是典型的多级决策问题,动态规划法在求解多级决策问题上具有独到优势。鉴于此,ACV2D优化模型采用动态规划法求解,正序以信号相位为阶段划分问题、以车辆预测到达时间前 $t_0$ 时刻为决策时间点,通过Bellman方程修正效益函数来确定最有利的控制动作,算法伪代码见图4。

## 3 仿真设计

### 3.1 仿真环境及参数设置

数字仿真基于Matlab完成,背景交叉口为四相位的十字交叉口,每个进口均为3条车道,车道功能分别为左转、直行和直右。参考文献[9,11],本文的仿真参数设置见表1。各进口的小时交通流量见表2。

### 3.2 方案设计

设计了3组仿真实验,共包含4种不同方法。实验1为不同流量、渗透率和允许误差范围下ACV2D方法的优化时间和性能分析,旨在标定虚拟检测断面和虚拟检测区间相关参数。实验2旨在确定ACV2D方法的控制效果,包含3种方法:ACV2D、3DQN和3DRQN,3种方法的具体差异对比见表3。实验3通过对比设置和不设置虚拟检测区间的ACV2D方法性能验证ACV2D方法设置虚拟检测区间的效益。

## 4 结果与讨论

### 4.1 结果分析

#### 4.1.1 参数标定

如图5所示,ACV2D方法时间复杂度主要受

```

开始程序
1   t←0
2   m←1
3   tm,begin←0
4   W←0
5   X←[0,⋯,0],V←[0,⋯,0],A←[0,⋯,0]//初始化矩阵X、V、A用于存储车辆位置、速度、加速度信息
6   Vv←[0,0,0,0],Vbest←[0,0,0,0]//初始化矩阵Vv、Vbest用于存储当前控制动作、最佳控制动作
7   X←[x1,1,1}(t),⋯,xm,n,i}(t)],V←[v1,1,1}(t),⋯,vm,n,i}(t)],A←[a1,1,1}(t),⋯,am,n,i}(t)]//检测各相位车辆状态并存储
8   while i<qmax//不为当前控制范围内最后一辆CV
9     i←i+1
10    while m<5
11      t←t+1
12      根据式(5)、(6)、(7)更新X、V、A//车辆状态更新
13      np}(t)←∑n=1nmax∑i=1qmaxβm,n,i}(tm,a)+∑n=1nmax∑i=1qmaxχm,n,i}(tm,a)
14      if t-tm,begin>Lm}(tm,begin),np}(t)≠np}(t-1)且t-tm,begin<60//决策时间点计算
15        Vv}[t-1]←[1,0,0,0]或Vv}[t-1]←[0,0,0,0]
16        if Vv}[t-1]=[1,0,0,0]
17          m←m+1
18        end if
19        if Vv}[t-1][1]≠0
20          根据式(2)计算ω(t)//计算控制动作收益并储存用于剪枝
21          Vv}[t-1][1]=ω(t)
22        else
23          ω(t)←Vv}[t-1][1]
24        end if
25      else if t-tm,begin≥60
26        m←m+1
27      end if
28    end while
29    W←max(∑ω(t),W)//确定最佳控制收益,并将相应控制动作确定为最优控制动作
30    Vbest←Vv
31  end while
结束程序
    
```

图4 ACV2D优化算法

Fig.4 ACV2D optimization algorithm

表1 仿真参数取值

Tab.1 The value of simulation parameter

参数名称	取值
仿真时间/s	3 600
CV渗透率	0.8
道路设计速度/(m·s <sup>-1</sup> )	13
启动波传递速度/(m·s <sup>-1</sup> )	6
平均车头间距/m	6
CV判断减速距离/m	25
黄灯时间/s	3
直行车道饱和和流率/(pcu·h <sup>-1</sup> )	1 300
仿真路段长度/m	400
车辆驶离交叉口目标车速/(m·s <sup>-1</sup> )	11
CV启动加速度/(m·s <sup>-2</sup> )	2.5
驾驶员反应时间/s	1
提前检测时间/s	1
CV判断换道距离/m	14
绿灯间隔/s	3
左转车道饱和和流率/(pcu·h <sup>-1</sup> )	1 000

表2 小时交通流量

Tab.2 Traffic volume per hour

进口	小时交通流量/(pcu·h <sup>-1</sup> )					
	左转			直行		
	低	中	高	低	中	高
北	63	81	103	402	604	807
南	79	93	118	428	659	859
东	59	88	109	413	618	824
西	57	72	91	457	627	883

表3 实验2的对比方案

Tab.3 Comparison scheme of experiment 2

方法	动作步长	记忆能力	效果验证	需要训练	额外检测设施
ACV2D	非固定	×	√	×	×
3DQN	固定	×	×	√	√
3DRQN	固定	√	×	√	√

CV 渗透率  $P_{CV}$  和交通流量的影响。流量提升会增加实施信号控制方案的数量及收益计算的复杂度;而  $P_{CV}$  则决定了当前交通流量下可被检测的车辆数,这些信息作为优化程序的输入影响算法的时间复杂度。在极限情况下(假设相位初始绿灯时间为零,且后续每秒都有车辆通过交叉口,绿灯利用恰好达到饱和),算法时间复杂度为  $O(k^1\mu) = O(1.296 \times 10^9)$ ,在 C++ 环境下算法复杂度为  $4 \times 10^8$  时需运行 1 s,则该算法最多需要 3.24 s,故提前检测时刻为 4 s,虚拟检测断面位置为  $4v_{os}$ 。




图5 算法时间复杂度变化

Fig.5 Algorithm time complexity change

保持  $P_{CV}$  不变,在低、中、高流量和不同误差允许范围  $\epsilon$  下各进行 50 次仿真,并对车均延误结果求均值,如图 6 所示。结果表明,车均延误随误差允许范围提高而提升。这是因为误差允许范围提高会导致控制精度下降,进而导致优化程序得到的最优信号控制方案与实际车辆运行情况不符。由图 6 可见,误差允许范围超过 30% 时车均延误会发生显著变化,故误差允许范围取 30%。




图6 车均延误随预测模型误差折降

Fig.6 Average delay per vehicle reduction with prediction model error

#### 4.1.2 ACV2D 方法自适应信号控制性能分析

低、中、高流量下,分别对 3DRQN、3DQN 和  $P_{CV}$  为 0.8、0.5 时的 ACV2D 方法进行 50 次仿真,结果如图 7 所示。




图7 3种方法车均延误对比

Fig.7 Comparison of average delay per vehicle between three methods

从图 7 可以看出,  $P_{CV}$  为 0.8 时,低、中、高流量下,ACV2D 方法性能均优于 3DQN 和 3DRQN 方法。ACV2D 方法控制下的车均延误分别为 11.03、18.45、20.97,较 3DQN 车均延误分别下降了 45%、29% 和 28%,较 3DRQN 则分别下降了 12%、9% 和

15%。这是因为ACV2D方法采用非固定控制步长,具有更高的控制精度,而3DQN和3DRQN方法则采用固定控制步长,每次执行控制动作时均可能产生绿灯时间浪费,控制精度有限。在低流量下,固定步长产生的绿灯时间浪费因各相位的放行需求不大而不明显,但随着交通流量的提高,各相位放行需求提高,同样长度的绿灯时间浪费将带来更多的额外延误,固定步长的弊端也更加明显。此外,3DQN和3DRQN方法无法实时验证实际交通状况与预期交通状况的符合度,也无法对控制方案进行修正,在交通状况波动较大时控制效果不佳。ACV2D方法则能够利用CVs实时反馈的信息,评估当前交通流状况与预测交通状况的吻合度,在误差超出可接受范围时更新控制方案,从而确保控制效果。

$P_{CV}$ 为50%时,低流量下ACV2D方法的车均延误为20.49 s,比3DQN方法高3%,比3DRQN方法高81%;中、高流量下,ACV2D方法的车均延误分别为23.84、26.59 s,相较于3DQN方法分别下降了8%和9%,相较于3DRQN方法分别提高17%和7%。这是因为,3DQN和3DRQN方法及现有其他基于强化学习的自适应信号控制方法多利用设置于道路上的车辆检测器,不受 $P_{CV}$ 的影响。ACV2D方法则采用CV作为车辆检测器,利用观测CV的异常速度变化结合跟驰模型判断HV位置。 $P_{CV}$ 不高时,交叉口的车流信息获取不准确,ACV2D方法的优势难以发挥。随着交通流量的提高,HV与CV的交互行为更容易被检测到,ACV2D方法获取的交叉口车流信息更加准确,因此控制效果也上升。

#### 4.1.3 虚拟检测区间效益分析

不同交通流量和 $P_{CV}$ 下对设置虚拟检测区间的ACV2D方法和不设置虚拟检测区间的ACV2D\*方法进行仿真并求均值,如图8所示。

结果显示,ACV2D方法在所有测试条件下均显著优于ACV2D\*方法,车均延误平均降低26.23%且标准差显著降低。这是因为虚拟检测区间能检测车辆实际运行状况与模型预测结果间差异较大的情况并更新控制方案,从而优化信号控制的效果与稳定性。具体而言,车辆实际运行状况与模型预测结果出现较大误差时有以下2种情况:

(1)驾驶员自身驾驶习惯等因素的影响。预测模型旨在理想化地预测未来车辆运行状态,但受驾驶员驾驶习惯等因素影响,车辆实际运行轨迹常与预测模型结果存在偏差。如图9a所示,未设置虚拟检测区间时,ACV2D\*方法的车均延误随预测精度提升而显

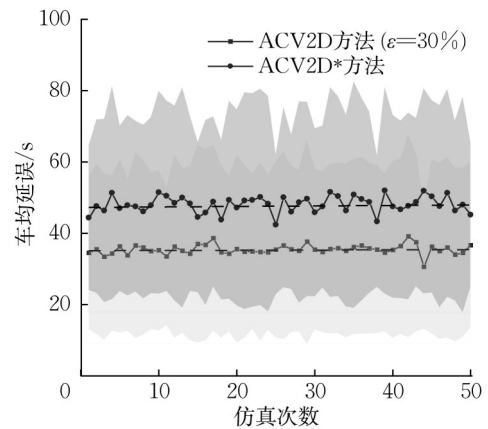


图8 2种方法车均延误对比

Fig.8 Comparison of average delay per vehicle between two methods

著减少。引入虚拟检测区间后,系统能检测出的实际运行状况与预测模型结果存在的较大偏差(如超过30%的误差),并及时更新控制方案,如图9b所示。

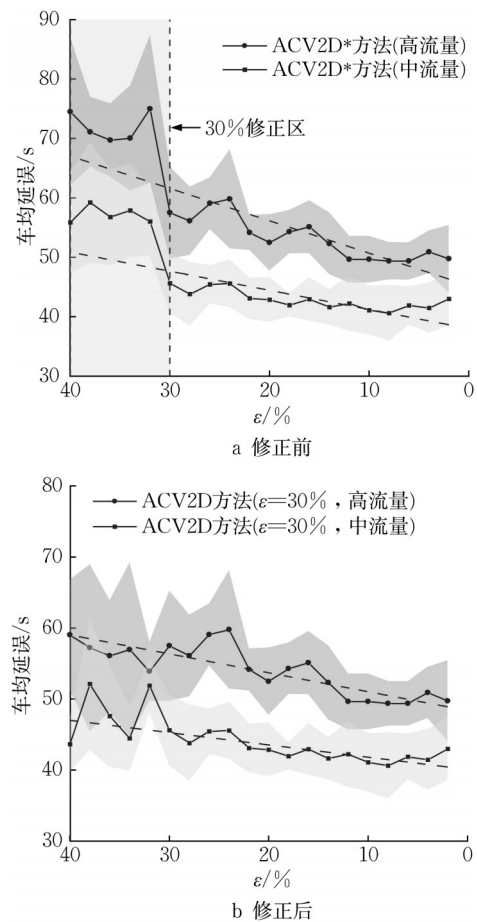


图9 虚拟检测区间修正效果

Fig.9 Effect of virtual detection interval correction

(2)预测模型输入状态变量缺失的影响。不同于设置检测设施的交叉口信号控制方法,ACV2D方

法仅基于CV轨迹的异常变化确定HV的位置。决策时刻当CV未跟驰到前方HV时,该HV无法被检测到,进而影响输入变量的准确性和控制方案的有效性。当未被检测到的HV在当前控制方案下后续不与其他CVs发生跟驰时,则在不设置虚拟检测区间的情况下仅影响ACV2D方法决策时刻的计算,即仅影响决策精度;当该HV在当前控制方案下后续与其他CVs发生跟驰时,在不设置虚拟检测区间的情况下对ACV2D方法的影响较大,不修正会产生大的延误。虚拟检测区间的使用可以减少无法被检测出的HVs,进而降低程序对于CV渗透率的依赖性。如图10所示,设置允许误差范围为30%的虚拟检测区间可以在提高算法性能的同时,降低算法性能随CV渗透率上升而上升的幅度。

#### 4.2 敏感度分析

保持关键车道组流率比之和Y值不变,改变CV

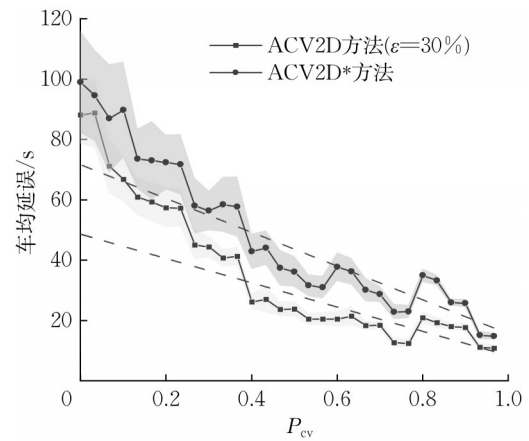





图 10 2种方法车均延误随渗透率的变化

Fig.10 Change in average delay per vehicle with CV penetration rate for two methods

渗透率进行多次仿真,如图11a所示。结果显示,车均延误随CV渗透率的提高而下降,且下降曲线的



a 车均延误随CV渗透率变化



b 车均延误随关键车道组流率比之和变化




图 11 车均延误随CV渗透率和关键车道组流率比之和变化

Fig.11 Average delay per vehicle varying with CV penetration rate and the sum of flow rate ratios of key lane groups

前后平均斜率差随 CV 渗透率的提高先提高后降低。这是因为 CV 渗透率的提高降低了系统的不确定性,进而提高了 ACV2D 方法的性能。在性能达到最佳之前,下降曲线的前后平均斜率差随 CV 渗透率的提高而提高;达到最佳性能之后,继续提高 CV 渗透率,ACV2D 方法性能基本不变,此时前后斜率差开始降低。前后斜率差极大值点对应的 CV 渗透率为当前 Y 值下使 ACV2D 方法达到最佳性能的 CV 渗透率。在 Y 值为 0.3 时,使 ACV2D 方法性能最佳的 CV 渗透率不低于 0.92,而当 Y 值为 0.7 时则不低于 0.61。随着 Y 值的提高,达到最佳性能的 CV 渗透率要求降低。这是因为交通流量提高, CV 更容易跟驰 HV,进而降低了 CV 渗透率需求。

保持 CV 渗透率不变,改变 Y 值进行多次仿真,如图 11b 所示。结果显示,车均延误随 Y 值的提高而提高,但曲线的前后平均斜率差变化情况不同。当 CV 渗透率为 0.4 时,前后斜率差先下降至极小值点,后上升到极大值点(也是最大值点),最后再下降。这是因为随着交通流量的提高, CV 渗透率需求降低,到极小值点时达到 ACV2D 方法最佳性能。Y 值继续提高时, ACV2D 方法性能基本不变,车均延误随交通流量提高而增长,到最大值点后性能开始下降,此时前后斜率差开始降低。最大值点为 ACV2D 方法适用的极限 Y 值,最大值和极小值之间的范围为 ACV2D 方法最佳性能范围。当 CV 渗透率为 0.8 时,前后斜率差先下降至极小值点,后上升到极大值点(非最大值点),最后再下降。这是因为随着交通流量的提高, CV 渗透率需求降低,到极小值点达到 ACV2D 方法最佳性能,而 Y 值继续提高时, ACV2D 方法性能基本不变。由于不存在最大值点,因此 ACV2D 方法性能未再次下降,极小值之后的范围均为 ACV2D 方法最佳性能范围。

## 5 结语

将 CV 充当动态检测器,利用 CV 轨迹的异常变化探测 HV,实现对混合交通流运行状况的检测;构建非固定步长、实时修正的动态规划模型,提出一种非完全网联交通环境下的自适应信号控制方法。仿真结果表明, ACV2D 方法相较于 3DQN 和 3DRQN 方法具有更好的控制性能。 ACV2D 方法的控制成效受 CV 渗透率和关键车道组流率比之和 2 个因素的共同影响, Y 值越大,确保 ACV2D 方法有效的 CV 渗透率要求就越低,反之亦然。

仅利用 CV 轨迹对 HV 的被动适应检测 HV,未考虑通过轨迹控制主动检测 HV,也未涉及车道均衡和油耗问题等,未来可在这些方面进行进一步研究。

### 作者贡献声明:

蒋贤才:方法构思,研究工作指导,论文修改。

邢 令:方法构思,程序实现,论文撰写与修改。

### 参考文献:

- [1] DUAN H M, XIAO X P, LONG J, *et al.* Tensor alternating least squares grey model and its application to short-term traffic flows[J]. *Applied Soft Computing*, 2020, 89: 106145.
- [2] CAI L, ZHANG Z, YANG J, *et al.* A noise-immune Kalman filter for short-term traffic flow forecasting [J]. *Physica A: Statistical Mechanics and Its Applications*, 2019, 536: 122601.
- [3] YANG H, JIN P J, RAN B, *et al.* Freeway traffic state estimation: a Lagrangian-space Kalman filter approach [J]. *Journal of Intelligent Transportation Systems*, 2019, 23(6): 525.
- [4] ZHOU Z, SCHUTTER B D, LIN S, *et al.* Two-level hierarchical model-based predictive control for large-scale urban traffic networks [J]. *IEEE Transactions on Control Systems Technology*, 2017, 25(2): 496.
- [5] YE B L, WU W, LI L, *et al.* A hierarchical model predictive control approach for signal splits optimization in large-scale urban road networks [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2016, 17(8): 2182.
- [6] YE B L, WU W, MAO W. Distributed model predictive control method for optimal coordination of signal splits in urban traffic networks [J]. *Asian Journal of Control*, 2015, 17(3): 775.
- [7] HONG W, TAO G, WANG H, *et al.* Traffic signal control with adaptive online-learning scheme using multiple-model neural networks [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 34(10): 7838.
- [8] 刘佳佳, 左兴权. 交叉口交通信号灯的模糊控制及优化研究 [J]. *系统仿真学报*, 2020, 32(12): 2401.  
LIU Jiajia, ZUO Xingquan. Research on fuzzy control and optimization for traffic lights at single intersection[J]. *Journal of System Simulation*, 2020, 32(12): 2401.
- [9] TOUHBI S, BABRAM M A, NGUYEN-HUU T, *et al.* Adaptive traffic signal control: exploring reward definition for reinforcement learning [J]. *Procedia Computer Science*, 2017, 109: 513.
- [10] LIANG X, DU X, WANG G, *et al.* A deep reinforcement learning network for traffic light cycle control [J]. *IEEE Transactions on Vehicular Technology*, 2019, 68(2): 1243.
- [11] 陆丽萍, 程昱, 褚端峰, 等. 基于竞争循环双 Q 网络的自适应交通信号控制 [J]. *中国公路学报*, 2022, 35(8): 267.  
LU Liping, CHENG Ken, CHU Duanfeng, *et al.* Adaptive

- traffic signal control based on dueling recurrent double Q network[J]. *China Journal of Highway and Transport*, 2022, 35(8): 267.
- [12] 郭海锋,程君,方良君,等.短时预测下的单点交叉口无模型自适应控制方法[J].*中国公路学报*, 2014, 27(12): 8.  
GUO Haifeng, CHENG Jun, FANG Liangjun, *et al.* Model-free adaptive control method for isolated intersection based on short-term prediction [J]. *China Journal of Highway and Transport*, 2014, 27(12): 8.
- [13] WANG Y, WANG Z. Distributed model free adaptive fault-tolerant consensus tracking control for multiagent systems with actuator faults[J]. *Information Sciences*, 2024, 664: 120313.
- [14] LIN W, WEI H. CAV-enabled data analytics for enhancing adaptive signal control safety environment [J]. *Accident Analysis and Prevention*, 2023, 192: 107290.
- [15] LIANG X J, GULER S I, GAYAH V V. An equitable traffic signal control scheme at isolated signalized intersections using connected vehicle technology [J]. *Transportation Research: Emerging Technologies*, 2020, 110:81.
- [16] MIRHELI A, TAJALLI M, HAJIBABAI L, *et al.* A consensus-based distributed trajectory control in a signal-free intersection [J]. *Transportation Research, Part C: Emerging Technologies*, 2019, 100: 161.
- [17] RAFTER C B, ANVARI B, BOX S, *et al.* Augmenting traffic signal control systems for urban road networks with connected vehicles [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2020, 21(4): 1728.
- [18] MILANES V, SHLADOVER S E. Modeling cooperative and autonomous adaptive cruise control dynamic responses using experimental data [J]. *Transportation Research, Part C: Emerging Technologies*, 2014, 48: 285.
- [19] 宗芳,李宇暄,贺正冰,等.基于混行跟驰仿真的CAV专用进口道动态设置方法[J].*中国公路学报*, 2022, 35(7): 10.  
ZONG Fang, LI Yuxuan, HE Zhengbing, *et al.* Dynamic layout design of connected and automated vehicle entrance lanes based on mixed-traffic car-following simulations [J]. *China Journal of Highway and Transport*, 2022, 35(7): 10.

### (上接第243页)

- Development of a reactive transport model for field-scale simulation of microbially induced carbonate precipitation [J]. *Water Resources Research*, 2019, 55(8): 7229.
- [70] CHENG L, CORD-RUWISCH R. In situ soil cementation with ureolytic bacteria by surface percolation [J]. *Ecological Engineering*, 2012, 42: 64.
- [71] CHENG L, CORD-RUWISCH R, SHAHIN M A. Cementation of sand soil by microbially induced calcite precipitation at various degrees of saturation [J]. *Canadian Geotechnical Journal*, 2013, 50(1): 81.
- [72] LIU J, LI G, LI X. Geotechnical engineering properties of soils solidified by microbially induced CaCO<sub>3</sub> precipitation (MICP)[J]. *Advances in Civil Engineering*, 2021, 2021(1): 6683930.
- [73] MITCHELL J K, SANTAMARINA J C. Biological considerations in geotechnical engineering [J]. *Journal of Geotechnical and Geoenvironmental Engineering*, 2005, 131(10): 1222.
- [74] MORTENSEN B M, HABER M J, DEJONG J T, *et al.* Effects of environmental factors on microbial induced calcium carbonate precipitation [J]. *Journal of Applied Microbiology*, 2011, 111(2): 338.
- [75] WANG H L, ZHANG Q Y, YIN Z Y, *et al.* Effect of sand particle size on interface shear behaviour between bio-cemented sand by MICP treatment and steel structure [J]. *Canadian Geotechnical Journal*, 2023, 60(3): 269.
- [76] CUI M J. Influence of cementation level on the strength behaviour of bio-cemented sand [J]. *Acta Geotechnica*, 2017, 12: 971.
- [77] BORDOLOI A D, SCHEIDWEILER D, DENTZ M, *et al.* Structure induced laminar vortices control anomalous dispersion in porous media [J]. *Nature Communications*, 2022, 13(1): 3820.
- [78] LI H, PAN C, MILLER C T. Pore-scale investigation of viscous coupling effects for two-phase flow in porous media [J]. *Physical Review E*, 2005, 72(2): 026705.
- [79] PRAT M. Recent advances in pore-scale models for drying of porous media [J]. *Chemical Engineering Journal*, 2002, 86: 153.
- [80] ZHANG T, KLAPPER I. Mathematical model of biofilm induced calcite precipitation [J]. *Water Science and Technology*, 2010, 61(11): 2957.
- [81] QIN C, HASSANIZADEH S M, EBIGBO A. Pore-scale network modeling of microbially induced calcium carbonate precipitation: insight into scale dependence of biogeochemical reaction rates [J]. *Water Resources Research*, 2016, 52(11): 8794.
- [82] NISHIMURA I, MATSUBARA H. Electricity-reaction-diffusion system for microbially induced carbonate precipitation [J]. *Soils and Foundations*, 2022, 62(5): 101217.
- [83] RAZBANI M A, JETTESTUEN E, RØYNE A. Direct pore-scale numerical simulation of microbially induced calcium carbonate precipitation [J]. *Water Resources Research*, 2023, 59(1): 1.