

引文格式：

刘章杰, 李慧云. 基于多目标协同演化算法的大规模自动驾驶策略 [J]. 集成技术, 2020, 9(5): 93-102.

Liu ZJ, Li HY. Optimal driving policies for large-scale autonomous vehicles based on multi-objective co-evolutionary algorithms [J]. Journal of Integration Technology, 2020, 9(5): 93-102.

基于多目标协同演化算法的大规模自动驾驶策略

刘章杰^{1,2,3} 李慧云^{1,2,3}

¹(中国科学院深圳先进技术研究院 深圳 518055)

²(中国科学院人机智能协同系统重点实验室 深圳 518055)

³(粤港澳人机智能协同系统联合实验室 深圳 518055)

摘 要 目前无人驾驶技术领域的研究重点主要集中在单车层面的感知、决策与控制，而缺少对多车之间交互及博弈的研究，因此无法有效降低交通系统整体事故率并提升通行效率。该文提出一种基于合作博弈理论的大规模自动驾驶策略涌现方法。通过建立面向网联汽车、多目标优化决策的合作博弈演化平台，并构造了一种网格道路模型和车辆运动学模型，使得系统中各车辆之间以近邻博弈的方式进行交互；同时系统采用分布式算法并具有间接交互的特点，最终模型计算复杂度与模拟车辆规模呈线性关系。实验结果表明，最佳策略涌现后，事故率和平均速度均取得明显改善，其中事故率降低了 90%，模型计算速度提升了 30%。该方法可应用于包含数百万辆自动驾驶汽车的城市级智能交通规划系统中。

关键词 自动驾驶策略；多目标；协同演化；博弈

中图分类号 V 323.19 文献标志码 A doi: 10.12146/j.issn.2095-3135.20200515002

Optimal Driving Policies for Large-scale Autonomous Vehicles Based on Multi-objective Co-evolutionary Algorithms

LIU Zhangjie^{1,2,3} LI Huiyun^{1,2,3}

¹(Shenzhen Institutes of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518055, China)

²(CAS Key Laboratory of Human-Machine Intelligence-Synergy Systems, Shenzhen Institutes of Advanced Technology, Shenzhen 518055, China)

³(Guangdong-Hong Kong-Macao Joint Laboratory of Human-Machine Intelligence-Synergy Systems, Shenzhen 518055, China)

Abstract Research in current autonomous driving domain mainly focused on the problems of perception, decision-making and control based on single autonomous vehicle, but the interactions and games among

收稿日期: 2020-05-15 修回日期: 2020-08-05

基金项目: 深圳市无人驾驶感知决策与执行技术工程实验室项目(Y7D004); 深圳电动汽车动力平台与安全技术重点实验室项目

作者简介: 刘章杰, 硕士, 研究方向为智能系统、演化博弈; 李慧云(通讯作者), 博士, 研究员, 博士研究生导师, 研究方向为安全芯片、智能系统等, E-mail: hy.li@siat.ac.cn.

different vehicles are usually ignored. That makes exiting techniques inapplicable to reduce the accident rate and to improve the traffic efficiency of the transportation system. To solve this problem, a decision-making emergence method is proposed for the large-scale autonomous driving system based on the principle of co-evolutionary games. We have established a grid road model and a vehicle kinematics model in which each vehicle interacts by indirect interaction. Benefited from the distributed algorithms and the communication method between vehicles, the computational complexity can be kept linear with the simulated vehicle volume. By designing a multi-objectives reward function, and making the co-evolution process in a simulated environment, the emergence of dominant driving strategies can be observed efficiently. Experimental results showed that the accidents rate and the average computation speed can be greatly improved compared with conventional approach. In details, the accident rate can be reduced by 90% and the average speed can be increased by 30%. The proposed method have great potentials to explore the optimal driving strategy for urban traffic up to millions of autonomous vehicles.

Keywords autonomous driving policy; multi-objective; co-evolution; game theory

1 引 言

随着经济的发展和车流密度的增加,城市交通拥堵日益严重,造成出行成本增加、通勤时间变长、事故率上升、经济损失增大和环境污染加剧等问题^[1-2]。如何实现大规模车辆协调驾驶,在平均速度、事故率等全局优化问题上取得突破已成为当前研究的重点和难点。

基于优化的中心化调度方法在较小的场景中能充分利用计算资源,因此在给定目标函数和约束条件的情况下,可采用中心化模型求解器进行优化求解。然而,中心化的优化算法(包括强化学习、神经网络和模糊逻辑等^[3])的计算复杂度随着交叉口数量、车辆规模、道路网络复杂程度以及车辆之间可能的冲突关系等的增加呈指数增长^[4]。即使未来的计算能力足够大,由于信息传输的延迟、丢失和计算时间,中心化服务器也很难实时响应交通请求。这是因为交通网络具有高度动态、瞬时变化的特点,所以几乎不可能以中心化的优化方法及时处理真实的交通事件和调度规划交通网络中的车辆。

而传统的演化算法(如遗传算法^[5]等)和一些智能优化算法(如蚁群算法、粒子群算法^[6-7]等),带有分布式的特点,能很好地处理规模庞大(地图复杂、车辆数量多)的问题。例如,研究人员引入分布式节点,针对整体交通流,提出蚁群算法和粒子群算法,综合考虑局部和全局最优的影响,不断调整搜索方向和搜索速度,并根据个体适应度进行迭代演化,在整体上能够较好地处理大规模优化问题^[8-9]。针对交通流调度优化问题,研究人员引入粒子群优化算法,对交通流和车辆进行分布式调度调整,从而缓解交通拥堵的情况^[10]。

但在车路协同网络中,传统的演化算法和智能优化算法存在以下问题:(1)仅创建单一种群,因为在车路协同网络中,车辆种类十分多元化,包括乘用车、商用车等,单一的种群环境不能满足演化的需要,同时在利用局部和全局信息上存在不充分的地方;(2)在对个体进行评价时,仅考虑个体在当前环境下的适应度,未能充分考虑在车路协同网络中个体车辆对其邻域环境的影响,以及个体之间的竞争与合作、个体与环

境之间、种群之间协作竞争的影响; (3) 传统的演化算法和智能优化算法在演化进程中, 容易收敛到局部最优并且收敛速度较慢。

本文提出基于协同演化算法的大规模无人驾驶系统决策优化方法, 建立面向网联汽车的多目标优化决策的博弈演化平台。通过构造网格道路模型, 建立简化的车辆运动学模型, 使得其中的各车辆之间以近邻博弈的方式进行交互。同时引入多种群环境和真实的道路交通环境, 构建真实道路模型和车辆动力学模型。在演化进程中, 充分考虑不同种群个体之间、个体与环境之间的影响。最终, 基于设计的奖励函数, 模拟生物种群相互竞争合作的演化进程, 从而在整体上观察网络中种群自发涌现的分布特点, 寻找不同环境下的最优驾驶策略。

2 相关研究进展

2.1 驾驶策略空间

随着车联网技术的发展, 良好的驾驶策略可以有效减少交通负荷并提高整体平均速度以及交通网络吞吐量, 而设计不当的驾驶策略则可能会导致交通拥堵甚至造成交通事故^[11-12]。驾驶策略可以分为 3 类^[13-15]: 保守型、理性型和激进型。其中, 保守型驾驶策略总是以相对较低的速度行驶; 理性型策略根据交通环境来调整速度和行为, 若前车速度较小且有足够的变道空间时, 则选择变道加速超车; 激进型策略总是以高速行驶, 且在前车速度较小时总是会选择超车。

本文基于 3 类驾驶行为策略的特点, 给出形式化的说明, 并引入 q 态模型和状态转换机, 形式化地描述 3 类策略在驾驶过程中的特点, 扩展驾驶策略空间, 在竞争与合作的更广泛的水平上探索各类策略交互的过程和结果。

2.2 协同演化算法

将达尔文的进化理论应用在自动化问题研

究方面已有较长时间。Fogel 等^[16]提出了进化规划, 以寻求针对众多工程问题的最佳解决方案。但是, 进化算法通常用于单个物种, 当一个物种进化时, 物种之间的选择压力随之改变, 其他物种也会做出反应并最终适应它——这导致物种之间的高度适应性现象^[17-18]。研究人员通过引入协同演化算法来探索两个或多个物种之间的相互作用^[19], 观察多个对象通过竞争或相互协作, 从而促进整体的发展^[20]。从数学的角度来看, 协同演化具有博弈论的动态特征, 最终通过连续演化的过程达到稳定的平衡状态^[21]。

在过去 20 年中, 演化算法 (Evolutionary Algorithms) 已被证明是解决多目标优化问题的有效方法。由于种群的本质, 多目标协同演化算法能够在单个算法执行中生成一组权衡的解决方案 (称为非主导解决方案), 而不必像通常使用数学编程技术那样执行一系列独立的方案。此外, 多目标协同演化算法可以成功地应用于具有诸如多边、不连续和不连续可行区域等困难特征的问题。另一方面, 协同演化算法是传统演化算法的扩展, 已应用于多目标优化问题的解决方案, 从而推动了新算法和分析公式的开发, 这些算法和分析公式同时也推动了协同演化算法研究的最新发展, 并在多目标协同演化算法中开辟了新的研究路径。

协同演化算法在相应的环境下构建多个子种群的方法有: 随机分解、模型构建和扰动构建。其中, 随机分解为随机选择基因的顺序, 通过事先评估或预实验决定分组的数量和大小; 模型构建为基于已有的演化模型构建种群和个体数量, 在演化过程中动态实施种群更新演化; 扰动构建为通过随机扰动或噪声的方式, 对决策变量进行扰动式分解。

与传统演化算法相比, 协同演化算法充分考虑种群之间以及种群与环境之间的相互影响, 并且充分考虑种群、个体之间的竞争与合作水平; 在评估个体时考虑该个体与其他种群个体之间的

交互关系, 在解决大规模全局优化问题时具有多层次、多操作、多选择的特点, 在高维度、多目标、大规模等问题中具有收敛速度快、优化质量高、可扩展性良好的优势。

3 问题描述与系统设计

3.1 问题描述

本文将大规模车辆集群的多目标优化问题描述为公式(1)所示, 优化策略 π 同时实现多个目标的优化, 包括最大化平均速度、最小化事故率等。

$$\min_{\pi} [f_1(x), f_2(x)] \quad (1)$$

第一个优化目标为:

$$f_1(x) = \sum_i \sum_j g_{i,j}(t) \cdot g_{i,j+1}(t) \quad (2)$$

其中, $f_1(x)$ 为事故数量, 即连续两个栅格被车辆占据时为发生了事故; $g_{i,j}(t)$ 为 t 时刻第 i 行 j 列处道路栅格(下见 3.3 小节)的状态; 当发生事故时, $g_{i,j}(t) \cdot g_{i,j+1}(t)$ 将为 1。

第二个优化目标为:

$$f_2(x) = -E[v(t)] \quad (3)$$

其中, $f_2(x)$ 为最大化所有车的平均速度; $v(t)$ 为 t 时刻整体车辆集群的速度; $E[v(t)]$ 为车辆集群整体的平均速度。

使得:

$$g_{i,j}(t) = \begin{cases} 1, & \exists k, s.t. c_{k,t} \in gr_{i,j} \\ 0, & \forall k, s.t. c_{k,t} \notin gr_{i,j} \end{cases} \quad (4)$$

$$E[v(t)] = \frac{\sum_k \sum_t \| \overline{v_{k,t}} \| \cdot \Delta t}{\sum_k \sum_t \Delta t} \quad (5)$$

$$\overline{v_{k,t}} = [v_{k,t}, \alpha_{k,t}] \quad (6)$$

$$v_{k,t} = v_{k,t-1} + \| \overline{a_{k,t}} \| \cdot \Delta t \quad (7)$$

$$\alpha_{k,t} = \alpha_{k,t-1} + \theta_{k,t} \quad (8)$$

$$v_{k,t} \leq v_{\max} \quad (9)$$

$$\| \overline{a_{k,t}} \| \leq a_{\max} \quad (10)$$

$$\theta_{k,t} \leq \theta_{\max} \quad (11)$$

其中, $c_{k,t}$ 为所定义的车辆中心点; $\overline{v_{k,t}}$ 为第 k 辆车 t 时刻的速度; $v_{k,t}$ 为第 k 辆车 t 时刻的速率; $\alpha_{k,t}$ 为第 k 辆车 t 时刻的车姿角度; $\theta_{k,t}$ 为第 k 辆车 t 时刻的方向盘转角; $\overline{a_{k,t}}$ 为第 k 辆车 t 时刻的加速度; Δt 为时间步长; $\| \bullet \|$ 为矢量二范数。

3.2 车辆模型

本文将车辆抽象为一个长 l 、宽 w 的矩形, 记为 $c_{k,t}$, 其中心点位于 $(x_{k,t}, y_{k,t})$, 如图 1 所示。

$$c_{k,t} : (x_{k,t}, y_{k,t}) \quad (12)$$

其中, $c_{k,t}$ 为第 k 辆车 t 时刻的几何中心; $x_{k,t}$ 为第 k 辆车 t 时刻几何中心的横坐标; $y_{k,t}$ 为第 k 辆车 t 时刻几何中心的纵坐标。

本文引入车辆运动学模型来描述车辆的行, 特别是其如何影响实际情况并促进群体之间的竞争和协作作用。

当车辆变道时, 模型如公式(13)~(18)所示:

$$v_{t+1} = v_t - \| \overline{a_t} \| \cdot \Delta t \quad (13)$$

$$x_{t+1} = x_t + v_{t+1} \cdot \cos(\alpha_t + \theta_t) \cdot \Delta t \quad (14)$$

$$y_{t+1} = y_t + v_{t+1} \cdot \sin(\alpha_t + \theta_t) \cdot \Delta t \quad (15)$$

$$x_{t+2} = x_{t+1} + v_{t+1} \cdot \cos(\alpha_t) \cdot \Delta t \quad (16)$$

$$y_{t+2} = y_{t+1} + v_{t+1} \cdot \sin(\alpha_t) \cdot \Delta t \quad (17)$$

$$v_{t+2} = v_{t+1} + \| \overline{a_t} \| \cdot \Delta t \quad (18)$$

当车辆转弯时, 模型如公式(19)~(22)所示:

$$x_{t+1} = x_t + v_{t+1} \cdot \cos(\alpha_t + \theta_t) \cdot \Delta t \quad (19)$$

$$y_{t+1} = y_t + v_{t+1} \cdot \sin(\alpha_t + \theta_t) \cdot \Delta t \quad (20)$$

$$x_{t+2} = x_{t+1} + v_{t+1} \cdot \cos(\alpha_t + \theta_t + \theta_{t+1}) \cdot \Delta t \quad (21)$$

$$y_{t+2} = y_{t+1} + v_{t+1} \cdot \sin(\alpha_t + \theta_t + \theta_{t+1}) \cdot \Delta t \quad (22)$$

当车辆路口处减速时, 模型如公式(23)~(24)所示:

$$d_t = \sqrt{(x_t - x_c)^2 + (y_t - y_c)^2} \quad (23)$$

$$v_{t+1} = v_t - \frac{v_t^2}{2d_t} \cdot \Delta t \quad (24)$$

其中, v_t 为车辆 t 时刻的速度; \overline{a}_t 为车辆 t 时刻的加速度; x_t 为车辆 t 时刻的几何中心横坐标; y_t 为车辆 t 时刻几何中心的纵坐标; α_t 为车辆 t 时刻的车姿角度; θ_t 为车辆 t 时刻的方向盘转角; x_c 为信号灯几何中心的横坐标; y_c 为信号灯几何中心的纵坐标; d_t 为车辆 t 时刻与信号灯的几何中心距离。

3.3 道路模型

本文提出的道路网格化模型中, 每个栅格都是一个正方形(长 gl =宽 gw), 网络栅格 $gr_{i,j}$ 位于 i 行 j 列且具有曲率 φ , 四个顶点坐标分别为 (gr_{x_0}, gr_{y_0}) 、 (gr_{x_0}, gr_{y_1}) 、 (gr_{x_1}, gr_{y_1}) 、 (gr_{x_1}, gr_{y_0}) 。每个栅格在旋转之后, 其区域可以由以下集合表示:

$$gr_{i,j} := \{(x, y) | gr_{x_0} < x < gr_{x_1}, gr_{y_0} < y < gr_{y_1}\} \quad (25)$$

将栅格长度 gl 设为等于车辆长度, 从而使每一个栅格中的车辆中心位不超过一辆。如图 1 所示, 车辆 A 的中心位于网格 $gr_{3,2}$ 中, 车辆 B 的中心位于另一个网格 $gr_{3,3}$ 中。随后, 本文采用公式(4)定义状态 $g_{i,j}(t)$ 的二进制状态。当车辆中心点落入网格中时, 网格将被占用, 其状态为 1; 当网格内部没有车辆时, 状态为 0。

利用本文所构建的道路模型和车辆模型, 单个车辆将仅与其相邻车辆间接交互。因此, 在每一个时间步长, 将交互复杂度从 $n!$ (n 为一个车邻域内车辆数量) 降到 n 。这样大大降低了模型的复杂性, 并增强了可扩展性。

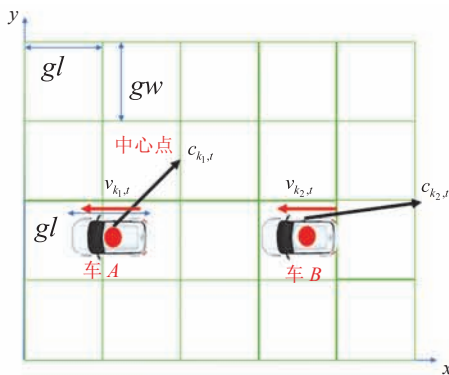


图 1 车辆与道路模型

Fig. 1 Vehicle and road model

3.4 策略的形式化表达

本文对多种候选驾驶策略进行探索。

(1) 保守型策略(即完全合作): 初始以最大速度行驶, 当前车的速度较慢时减速, 不超车, 避免强烈地使用油门和刹车。

(2) 激进型策略(即完全竞争): 总是以最高速度行驶, 遇到前车的速度较慢时始终超车。

(3) 理性型策略(介于完全合作与完全竞争之间): 温和地使用油门和刹车, 遇到前车的速度较慢时, 可选择超车或减速。

对于理性型策略, 本文采用 q 态 Potts 模型描述其竞争和合作的不同程度。

$$S_i \in \Omega \equiv \left\{ 0, \frac{1}{q-1}, \frac{2}{q-1}, \dots, \frac{q-2}{q-1}, 1 \right\} \quad (26)$$

其形式化描述为:

如果,

$$g_{i,j}(t) \cdot g_{i,j+2}(t) = 1 \ \& \ \| \overline{v}_{k_1,t} \| < \| \overline{v}_{k_2,t} \| \quad (27)$$

那么,

$$v_{k,t} := \begin{cases} v_{k,t-1} + \| \overline{a}_{k,t} \| \cdot \Delta t, \ \| \overline{a}_{k,t} \| < 0 & \text{保守策略} \\ v_{k,t-1} + \| \overline{a}_{k,t} \| \cdot \Delta t, \ \| \overline{a}_{k,t} \| < 0, \ \text{if } \sum_{n=i-4}^{i+2} g_{n,j}(t) > 0 & \text{理性策略} \\ v_{k,t-1}, \ \theta_{k,t} \neq 0, \ \text{if } \sum_{n=i-4}^{i+2} g_{n,j}(t) = 0 & \\ v_{k,t-1}, \ \theta_{k,t} \neq 0 & \text{激进策略} \end{cases} \quad (28)$$

设车辆当前状态 $A := [v_{k,t-1}, \alpha_{k,t-1}]$; 车辆下

一时刻状态 $B := [v_{k,t}, \alpha_{k,t}] := [v_{k,t-1} - \| \overline{a}_{k,t} \| \cdot \Delta t, \alpha_{k,t-1}]$,

即单辆车在下一时刻减速的状态; 车辆下一时刻

状态 $C := [v_{k,t}, \alpha_{k,t}] := [v_{k,t-1}, \alpha_{k,t-1} + \theta_{k,t}]$, $\theta_{k,t} \neq 0$,

即单辆车在下一时刻变道超车的状态; 则介于保守策略与激进策略之间的理性策略的状态转换如图 2 所示。

3.5 算法流程

本文探索候选策略步骤如下:

(1) 初始化道路和车辆种群, 其中随机设置车辆目的地。

(2) 根据车辆运动学模型运行车辆以及模拟

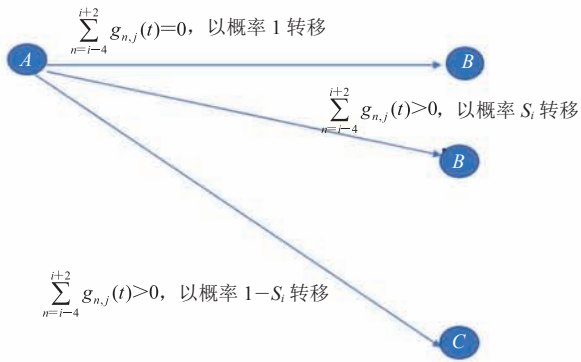


图2 状态转换图

Fig. 2 State transition diagram

交通信号灯，直到所有车辆到达目的地。在每个时间步长更新道路环境(即网格状态)。

(3)记录单个车辆的数据，如速度和事故。然后，根据公式(29)奖励函数评估车辆性能得分：

$$r(k) = -\beta_1 \cdot \eta + \beta_2 \cdot \left(\sum_t \|\bar{v}_{k,t}\| \cdot \Delta t / T_k - \bar{v} \right) \cdot \frac{1}{\delta_v} \quad (29)$$

其中， $r(k)$ 为第 k 辆车的奖励函数； η 为由第 k 辆车造成的事故； T_k 为第 k 辆车的生命周期； \bar{v} 为所有车辆的平均速度； δ_v 为所有车速度的标准差； β_1 、 β_2 为各项权重。

(4)获得总体种群车辆得分的平均值 μ 和标准差 δ 。根据图3所示的后代繁衍规则，确定每个单独车辆的后代数。繁衍完成后，归一化种群数量和大小，确保交通流密度不变，继续下一代模拟运行。其中，后代繁衍规则进行3个层次的划分。




图3 后代繁衍数量根据得分数据而有所不同

Fig. 3 The number of offspring varies according to the scores

繁衍规则①，策略得分高于平均数两个标准偏差字段 (2σ) 的车辆将有 2 个后代；

繁衍规则②，得分高于平均数到一个标准偏差字段 (1σ) 的车辆仅有 1 个后代。

繁衍规则③，分数低于平均值的车辆不会繁殖。

值得一提的是，这些规则具有实际意义，因为驾驶策略不佳可能会导致驾照被吊销甚至出现伤亡，而良好的驾驶策略则会被模仿。

(5)种群分布趋于稳定时终止。

本文算法流程如图4所示。

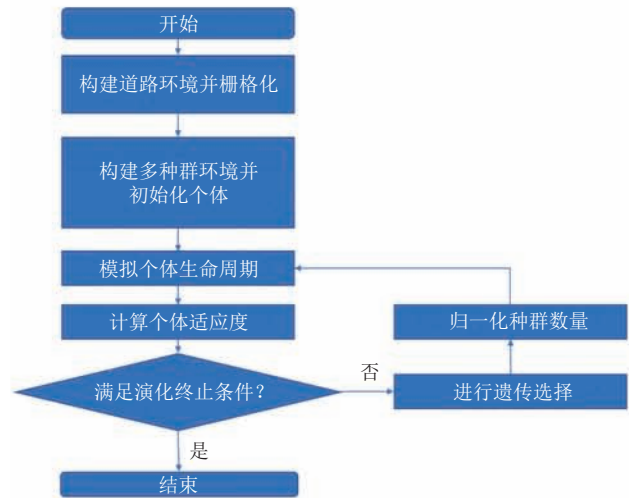


图4 系统流程图

Fig. 4 System flow chart

4 实验结果与数据分析系

4.1 实验环境

4.1.1 道路环境

在不失一般性的前提下，本文选择广东省深圳市的一个城市交通场景(图5黑色虚线)进行实验。其中，道路总长超过 4.5 km，每条车道宽 3.75 m，符合中国道路的建设标准。实验中，从 OSM(开放式街道地图)中导入矢量地图，其中每个车道由中心线上的一组点表示，然后通过等间隔插值对车道中的点进行采样，以获得每个网格

的中心点以及该点的曲率, 以建立 3.3 小节中介绍的道路网格模型。



图 5 城市道路环境

Fig. 5 Urban road environment

4.1.2 车辆

车辆总数设置为 340, 最初在该区域内随机分布, 并根据不同的策略分为多个种群。交通密度大约为 0.006 辆/ m^2 。需要说明的是, 该水平的车辆密度在城市高速公路中非常常见。例如, Jing 等^[22]研究给出的实际交通数据显示, 北京主干路网的平均交通流量每天超过 16 h 高于 0.005 辆/ m^2 。

实验中, 所有车辆的目的地均为随机设置。在车辆的生命周期中, 每辆车都会根据自己的策略与其他车辆及道路交互, 从而影响其他车辆并促进整体发展。

4.1.3 交通灯调度

在城市交通中, 常见使用的交通信号灯为固定时间片轮转算法, 其中每个时间片长度为 8 s。

4.1.4 候选驾驶策略

本文共对 3 种候选驾驶策略进行研究: (1) 保守型策略——不超车, 以最大速度行驶, 当前车的速度较慢时减速, 保持不超车; (2) 理性型策略——以最大速度行驶, 当前方车辆的速度较慢且有足够变道超车的空间时变道超车; (3) 激进型策略——以最高速度行驶, 且始终超车。

本文研究的具体实验参数如表 1 所示。

表 1 实验参数列表

Table 1 The list of experiment parameters

参数	数值	备注
道路长度	大约 4.5 km	双向四车道
车道宽度	3.75 m	采用中国标准车道宽度
仿真时间步长	0.4 s	以最大速度行驶距离约为 6 m
车辆总数	340 辆	
红绿灯调度算法	固定时间片轮转算法	每个时间片长度为 8 s
候选策略数量	3	保守型、理性型和激进型(扩展后增加中间策略), 共 5 种
v_{max}	60 km/h	最大速度
a_{max}	$5 m/s^2$	最大加速度
θ_{max}	30°	最大方向盘转角

4.2 实验结果

本文在模拟仿真环境中 4.5 km 的道路上进行了 340 辆汽车的实验。其中, 本文实验采用 Python 开发。

图 6 为 3 种候选策略种群演化结果。由于交通流密度较大, 激进型策略出现了大量事故(图 6(b)), 受激进型策略的影响, 保守型策略和理性型策略同样产生事故(急速刹车)。从图 6(c)可看出, 激进型和理性型策略取得较高的平均速度, 而保守型策略的较低。经过 50 代演化后, 理性型策略胜出, 保守型策略和激进型策略均被淘汰(图 6(a))。

另外, 本文引入变道因子 p 来描述更多的中间候选策略。中间策略描述为: 当遇到前车较低速度且有足够超车空间时, 变道超车; 当没有足够空间时, 则以概率 p 超车。例如, “0.3 型中间策略”表示在没有足够变道空间时以 0.3 的概率变道。

$$v_{k,j} := \begin{cases} v_{k,j-1} + \frac{a_{k,j}}{\|a_{k,j}\|} \cdot \Delta t, & P(\|a_{k,j}\| < 0) = 1 - p, \text{ if } \sum_{n=i-4}^{i+2} g_{n,j}(t) > 0 \\ v_{k,j-1}, \theta_{k,j} \neq 0, & \text{if } \sum_{n=i-4}^{i+2} g_{n,j}(t) = 0 \\ v_{k,j-1}, P\{\theta_{k,j} \neq 0\} = p, & \text{if } \sum_{n=i-4}^{i+2} g_{n,j}(t) > 0 \end{cases} \quad (30)$$

如图 7(a)所示, 当出现多代事故为 0 后, 种群分布处于收敛状态(事故为 0, 各种群速度接




图6 三种候选策略种群演化结果

Fig. 6 Result of evolution for multi-population with 3 candidate policies

近), 各策略层次分明, 与变道因子 p 呈现反相关 (激进型策略实际上是 $p=1$)。图 7(c) 显示, 保守策略的平均速度明显较低, 所以被快速淘汰; 图 7(b) 显示, 整体事故随着演化进程逐步降低, 最后趋于 0。

4.3 讨论与分析

从上述实验结果可知, 在确保安全和有足够空间的情况下, 应该保持高速行驶 (低速时应该加速); 交通流密度较高时, 不应该频繁变道及剧烈加速, 否则容易引起事故, 造成交通拥堵;

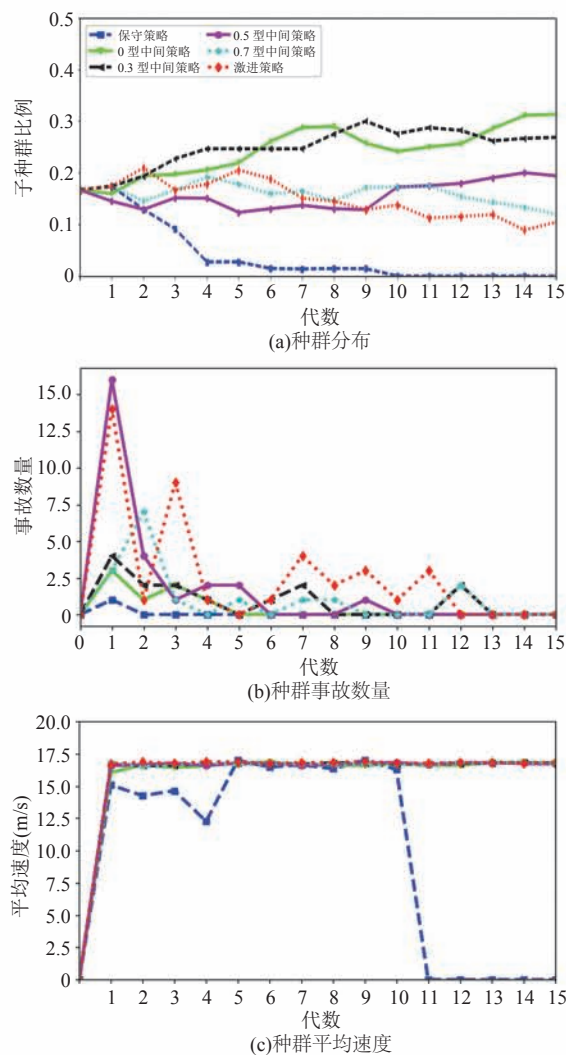


图7 多种候选策略(包括3种中间策略)种群演化结果

Fig. 7 Result of evolution for multi-population with 6 candidate policies

而在交通流密度较低时, 驾驶策略应偏向于激进策略, 在道路资源利用率上更加充分, 同时速度上具有明显的优势。

在引入基于 q 态模型的中间策略、扩展了驾驶策略空间后, 种群分布表现出了明显的层次性。在交通流密度较高时, 策略表现与变道因子大致呈反相关关系。其中在 9~12 代, “0.3 型中间策略” 表现最优, 事故率为 0, 平均速度较 “0 型中间策略” 略微占优, 总体得分最高。这表明在驾驶过程中, 对于安全距离和足够变道空

间的评估不能过于谨慎, 否则可能会浪费道路资源, 降低车辆平均速度。

表 2 将本文方法与现有的一些文献方法进行对比。移动模型 (Mobility Model)^[23] 采用群体智能方法降低计算复杂度, 由于采取演化规则不当, 导致拥堵出现, 平均速度较低; 本文采用协同演化的方法, 并且设置良好的演化规则, 避免了拥堵的出现。Zhou 等^[24] 提出的基于两层混合模型的预测控制调度采用双层模型、区域分割、信号灯调度的方法, 增加了路口的吞吐量及减少了路口的等待时间, 由于采用的最大速度约束不同, 平均速度结果也不同。本文引入栅格道路模型, 采用分布式算法, 降低了仿真时间; 但是由于本文实验信号灯采用时间片轮转算法, 路口吞吐量没有较好的兼顾, 后续工作可以进一步改进交通的调度方式。与上述两种方法相比, 由于本文为了探索驾驶策略对事故率的影响, 在仿真环境下事故率仍然没有为 0, 未来工作可以考虑进一步优化事故率。国家统计局数据^[25] 显示, 2019 年平均每月事故率为 0.804 ‰, 本文多目标优化后事故率小于 0.5 ‰, 提升了 37%。由此可见, 本文方法在平均速度、事故率与现有方法相比均有一定程度的下降。

表 2 不同仿真结果对比

Table 2 The comparison of simulation result

方法	平均速度 (m/s)	事故率* (‰)	仿真时间(s)
移动模型 ^[23]	11.1	0	--
现实情况 ^[25]	--	0.804	--
Zhou 等 ^[24] 方法	约 13.89	0	900
本文涌现策略	16.3	<0.5	180

注: “*” 采用每万辆车平均每月事故数量^[26] 表示事故频率, 简称事故率;

“--” 为在相应文献中无该项指标

实验配备为 2 GHz 处理器和 8 GB 内存的 MacBook Pro, 实验仿真时间为 3 min。由于本文采用分布式的协同演化算法, 且栅格化道路之后, 车辆之间采用间接交互的方式, 个体车辆在

每个时间步长内仅与其领域内的车辆进行间接交互, 故总体计算复杂度与车辆数量成线性关系, 并且可以并行处理, 因此可以扩展本方法用于探索包含数百万辆自动驾驶汽车的城市级的驾驶策略。

5 总结与展望

由于城市自动驾驶汽车具有大规模和高动态特性的特点, 因此不再适合采用中心化优化调度算法。本文将大规模的城市自动驾驶策略优化问题表述为众多子群体之间的多目标优化的协同演化问题, 并希望观察具有代表性的候选策略中最优驾驶政策的自发涌现。

在模拟环境中进行了 4.5 km 道路上不同交通流密度下 (车辆数量分别为 170 辆、340 辆) 的实验。结果显示, 理性型策略可以达到最佳效果; 激进型策略产生的事故最高, 平均速度也略高; 保守型驾驶策略表现最差, 25 代后就被淘汰了。采取最佳策略后, 事故总数和平均速度均取得了巨大的提升。其中, 事故数量趋于 0, 事故率降低为 0.05% 以下 (降低 90%); 平均速度方面由于保守策略的占比下降得以显著提升, 由 13.8 m/s 提升到了 16.3 m/s (提升 30%)。

在此基础上, 本文引入基于 q 态模型的中间策略, 并在相同环境下进行了模拟演化实验, 其中选取交通流密度为 0.006 辆/m²。在演化过程中, 出现了明显的分层趋势, 表现出在该交通流密度下, 变道因子越高, 策略表现越差的特点, 经过 15 代的演化进程, 多代事故数量趋于 0, 各种群平均速度相差不大, 种群比例保持相对稳定, 达到收敛状态; 在淘汰了保守策略后, 平均速度达到了 16.4 m/s。在本文所提出的方法中, 由于各车辆之间以近邻博弈的方式进行交互, 使得计算复杂度与模拟的车辆规模大小呈线性关系, 故可扩展至包含百万辆自动驾驶汽车的城市

级驾驶策略探索。

参 考 文 献

- [1] 全永桑, 刘莹, 陈金川. 中国城市交通问题剖析及改善对策 [J]. 城市交通, 2007, 5(4): 5-9.
- [2] Pinto JA, Kumar P, Alonso MF, et al. Traffic data in air quality modeling: a review of key variables, improvements in results, open problems and challenges in current research [J]. Atmospheric Pollution Research, 2020, 11(3): 454-468.
- [3] Goel S, Bush SF, Gershenson C. Self-organization in traffic lights: evolution of signal control with advances in sensors and communications [Z/OL]. arXiv Preprint, arXiv:170807188, 2017.
- [4] Papadimitriou CH, Tsitsiklis JN. The complexity of optimal queuing network control [J]. Mathematics of Operations Research, 1999, 24(2): 293-305.
- [5] Bazzan AL. A distributed approach for coordination of traffic signal agents [J]. Autonomous Agents and Multi-Agent Systems, 2005, 10(1): 131-164.
- [6] Kennedy J, Eberhart R. Particle swarm optimization [C] // Proceedings of ICNN'95-International Conference on Neural Networks, 1995, DOI: 10.1109/ICNN.1995.488968.
- [7] Tatomir B, Rothkrantz L. Ant based mechanism for crisis response coordination [C] // Proceedings of the 5th International Conference on Ant Colony Optimization and Swarm Intelligence, 2006: 380-387.
- [8] Zhang YQ, Wang ML, Liu T, et al. An extended variable speed limit strategy for intelligent freeway traffic optimization [C] // Proceedings of the 2018 IEEE CSAA Guidance, Navigation and Control Conference (CGNCC), 2018, DOI: 10.1109/GNCC42960.2018.9018918.
- [9] Wang XJ, Ning ZL, Hu XP, et al. A city-wide real-time traffic management system: enabling crowdsensing in social Internet of vehicles [J]. IEEE Communications Magazine, 2018, 56(9): 19-25.
- [10] Li QY, Wei SQ, Cai BG, et al. Traffic flow guidance and optimization of connected vehicles based on swarm intelligence [C] // Proceedings of the 2019 Chinese Control Conference (CCC), 2019, DOI: 10.23919/ChiCC.2019.8866595.
- [11] Chen JR, Wu YF, Huang HJ, et al. Driving-data-driven platform of driving behavior spectrum for vehicle networks [C] // Proceedings of the 2018 IEEE 20th International Conference on High Performance Computing and Communications, 2018: 518-525.
- [12] Hu J, Xu L, He X, et al. Abnormal driving detection based on normalized driving behavior [J]. IEEE Transactions on Vehicular Technology, 2017, 66(8): 6645-6652.
- [13] Li L, Song JY, Wang FY, et al. IVS 05: new developments and research trends for intelligent vehicles [J]. IEEE Intelligent Systems, 2005, 20(4): 10-14.
- [14] Wang L, Yang XG. New controlling methods for alleviating recurrent congestion on freeway merge area [C] // CICTP 2012: Multimodal Transportation Systems—Convenient, Safe, Cost-Effective, Efficient, 2012: 1035-1043.
- [15] Cheng AY, Xiong QH, Wang L, et al. Design of drive control strategy for mini pure electric vehicles on the condition of slope climbing [C] // Proceedings of the 2019 Chinese Control and Decision Conference (CCDC), 2019, DOI: 10.1109/CCDC.2019.8833155.
- [16] Fogel LJ, Owens AJ, Walsh MJ. Artificial intelligence through simulated evolution [M] // Evolutionary Computation: the Fossil Record, 1966: 227-296.
- [17] Whitley D. A genetic algorithm tutorial [J]. Statistics and Computing, 1994, 4(2): 65-85.
- [18] 董红斌, 黄厚宽, 印桂生, 等. 协同演化算法研究进展 [J]. 计算机研究与发展, 2008, 45(3): 454-463.
- [19] 王凌, 沈婧楠, 王圣尧, 等. 协同进化算法研究进展 [J]. 控与决策, 2015, 30(2): 193-202.
- [20] Wang G, Hu JM, Li ZH, et al. Cooperative lane changing via deep reinforcement learning [Z/OL]. arXiv Preprint, arXiv:1906.08662, 2019.
- [21] Chalkiadakis G, Elkind E, Wooldridge M. Cooperative game theory: basic concepts and computational challenges [J]. IEEE Intelligent Systems, 2012, 27(3): 86-90.
- [22] Jing BY, Wu L, Mao HJ, et al. Development of a vehicle emission inventory with high temporal-spatial resolution based on NRT traffic data and its impact on air pollution in Beijing—Part I: development and evaluation of vehicle emission inventory [J]. Atmospheric Chemistry and Physics, 2016, 16(5): 3161-3170.
- [23] Li LJ, Li L, Xia Q. A novel mobility model for urban VANETs inspired by biological collective intelligence [C] // Proceedings of the 2013 International Conference on Computational Problem-Solving (ICCP), 2013, DOI: 10.1109/ICCP.2013.6893567.
- [24] Zhou Z, Lin S, Du WL, et al. Integration of regional demand management and signals control for urban traffic networks [J]. IEEE Access, 2019, 7(20): 20235-20248.
- [25] 国家统计局. 公共管理、社会保障及其他: 交通事故 [DB/OL]. [2020-08-10]. <http://data.stats.gov.cn/easyquery.htm?cn=C01&zb=A0S0D01&sj=2019>.
- [26] 国家统计局. 民用汽车拥有量 [DB/OL]. [2020-08-10]. <http://data.stats.gov.cn/search.htm?s=%E6%B1%BD%E8%BD%A6>.