



研究与开发

基于数字孪生的城市交通流智能预测与导引策略

廖熙雯, 冷甦鹏, 明昱君, 李天扬

(电子科技大学信息与通信工程学院, 四川 成都 611731)

摘要: 物联网和人工智能等信息技术的快速发展极大地推动了交通系统的变革, 同样也带来了机遇与挑战。针对现有导航系统忽略交通流时空特征而产生的策略重复性拥堵问题, 对宏观交通流和微观车辆驾驶分别建模, 并挖掘其耦合关系, 进而提出一种基于数字孪生的城市智能交通流分层预测与导引策略, 为减缓交通拥堵提供新思路。在该策略中, 虚拟空间中的上层道路孪生通过扩散卷积递归神经网络预测时空交通流量, 并显式作用于车辆路径规划决策。在此基础上, 提出一种时空协同深度强化学习方法, 用于实现车辆面向未来的协作式路径规划, 指导虚拟空间中的下层车辆孪生选出最优策略反馈于真实世界。基于 SUMO 仿真平台进行了仿真验证。实验结果表明, 本文所提方法在提高出行达成率、缓解拥堵等方面显著优于现有算法, 能够有效提升城市交通出行效率。

关键词: 数字孪生; 交通拥堵; 深度强化学习; 交通流预测与导引; 扩散卷积

中图分类号: TP393

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2023047

Digital twin based intelligent urban traffic forecasting and guidance strategy

LIAO Xiwen, LENG Supeng, MING Yujun, LI Tianyang

School of Information and Communication Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China

Abstract: As the technology of ubiquitous Internet of things and artificial intelligence improves by leaps and bounds, the transportation system revolution is flourishing and bringing new opportunities and challenges. Considering the defect in the existing navigation system, and the neglect of the temporal and spatial characteristics of traffic flow, the macro traffic network and micro vehicle network were modeled and their coupling relationship was mined. Then, a digital twin based urban traffic forecasting and guidance method was proposed to alleviate the problem of traffic congestion. The spatial-temporal traffic flow information was predicted through the diffusion convolution recurrent neural network, which was explicitly applied to the vehicle path planning decision. On this basis, a spatial-temporal collaborative deep reinforcement learning method was proposed to implement the future-oriented collaborative path

收稿日期: 2022-05-19; 修回日期: 2023-03-09

基金项目: 国家重点研发计划项目 (No.2018YFE0117500); 国家自然科学基金资助项目 (No.62171104)

Foundation Items: The National Key Research and Development Program of China (No.2018YFE0117500), The National Natural Science Foundation of China (No. 62171104)

planning of vehicles. It also guided the underlying vehicle twins to select the optimal strategy for the real world. With SUMO for simulation verification, the experimental results show that the proposed method is significantly better than the existing algorithms in improving the travel completion ratio and congestion relief, and can improve the efficiency of urban traffic travel.

Key words: digital twin, traffic congestion, deep reinforcement learning, traffic flow forecasting and guidance, diffusion convolution

0 引言

随着车辆数量的激增,城市交通拥堵成为愈发严重的问题。据调查,2021年,某城市用于解决交通拥堵所消耗的成本约占该城市GDP的3%~5%,这一数据还将随着人均车辆拥有量的增加而进一步提升^[1]。现有的主流导航应用可以帮助车辆优化驾驶路线,告知当前交通阻塞点,并建议替代路线,然而此类方法立足于车辆个体,无法提升交通整体出行效率^[2]。事实上,城市交通系统中存在着复杂的个体与系统、短期与长期效益的折中问题。例如,对于一些拥堵点和道路瓶颈,现有导航算法会驱使过多车辆以相同的策略涌入当前的通畅道路,造成后续拥堵。事实上,城市交通流具有复杂的时空流动性,某路段的交通流由前一段时间内其他路段的车辆汇聚而来,这种流动性的时间尺度相对缓慢。为了提升系统整体出行效率,在进行交通流导引时,需要充分考虑交通流量的时空流动性,提前为车辆规划或更改路径,避免轨迹时空交叠造成拥堵。

现有的针对交通流导引的研究很少考虑交通时空流动特征,主要有两点原因:首先,交通时空流动性的研究大多围绕交通流量预测展开,经典的交通流量预测方法有扩散卷积递归神经网络(DCRNN)^[3]、时空图注意力卷积神经网络(ASTGCN)^[4]等。交通流量预测的结果是宏观的路段流量数据,将这些预测的宏观数据应用于微观车辆导引需要复杂的数据转换和处理。其次,由于城市交通的高动态性,预测和决策模型都需要根据所处环境实时更新,以保证模型的适用性,

这在实际物理空间中是难以实现的。城市交通系统是一个随机复杂动态的巨型系统,如何将深度学习、强化学习等技术灵活运用于该领域,并达到有效提升城市交通系统的状态感知、流量预测、行为决策能力的目的,仍然是一个难题。

因此,本文提出一种基于分层数字孪生的城市智能时空交通流预测与导引框架,用于挖掘复杂城市系统内交通流量的时空流动性,基于城市交通的实时感知,实现拥堵预测和车辆时空导引决策。具体而言,在虚拟空间上层对城市道路拓扑建立映射,根据物理世界感知数据进行交通流预测,引导虚拟空间中的下层车辆完成面向未来的路径规划。车辆孪生根据不断更新的时空交通流预测,实时规划路径,并反馈于物理空间中的真实车辆。通过物理道路、预测模型、决策模型、物理车辆之间的闭环迭代,实现城市道路内车辆的时空协同决策,提高系统内车辆整体出行效率。

本文主要贡献如下。

(1) 针对城市交通系统提出一种基于分层数字孪生的城市交通流控制方案,分别从城市道路拓扑和车辆个体两个角度建立虚拟映射。在虚拟空间上层以图的方式对真实道路拓扑创建模型,进行宏观交通流的预测,在虚拟空间下层对车辆个体创建模型,通过深度强化学习实现微观路径规划。借助分层的孪生结构不断挖掘宏观交通流量和微观车辆决策之间的耦合关系,有效提升城市交通系统的感知、预测、决策能力。

(2) 设计了基于扩散卷积递归网络的交通流量预测算法,在道路孪生层分别从空间和时间两个维度捕捉交通流特征。其中,通过分子随机扩



散过程模拟车辆移动捕捉空间相关性,同时结合门递归单元捕捉时间相关性。为了实现多步预测,本文在算法中引入序列模型,充分提取门递归单元中的隐状态信息。该算法能有效挖掘时空特征,提高交通流预测精度。

(3) 提出一种时空协同深度强化学习方法,用于实现面向未来的协同路径规划。针对传统强化学习忽略时空相关性的问题,将道路孪生预测的时空交通流预测数据作为状态输入。下层车辆孪生进行路径规划时,不仅考虑车辆本身的出行需求和周遭感知数据,还考虑上层道路孪生对于未来路况的显式判断。此外,本文提出一种基于车辆优先级的协同奖励值设计方法,使车辆决策时充分权衡自身利益与对周围未来路况所带来影响,实现系统内不同车辆间的差异化协同决策。

1 国内外研究现状

为实现有效的交通流导引,缓解城市交通拥堵,首先要对交通流进行精准预测。国内外学者在交通流预测领域展开了广泛的研究,国内外在交通流预测方面的研究热点主要集中于组合模型^[5],是通过多种模型相互叠加来捕捉交通数据中复杂的线性和非线性特征,由于其可以综合不同模型优势,提取到更加全面的特征,从而被广泛应用。然而单个车辆对信息的采集和处理能力都非常有限,很难以分布式的方法获取全局信息并做出具有时空协同能力的决策。

数字孪生为解决以上问题提供了有力途径。2010年,美国航天局在太空路线图中首次引入“数字孪生”的概念^[6],对飞行系统全面的诊断和预测。在数字孪生和交通系统的交汇领域,Brunner等^[7]提出了一种基于数字孪生的自动驾驶安全性评估方法,旨在运用动力力学、认知学和行为学模型模拟因戈尔施塔特的城市道路网络,从而对自动驾驶技术进行全面测试。Hu等^[8]基于5G传输的交通流量建立数字孪生,将实体车辆和

其虚拟表现结合预测实时交通流量,实现快速和高精度的响应。Alam等^[9]提出了一个基于云的赛博数字孪生体系构架,利用贝叶斯网络和模糊规则增强系统重构能力,并应用于车载信息技术辅助驾驶。Du等^[10]提出一种针对城市轨道交通的数字孪生构架,模拟物理轨道交通的运行状况实时反馈于真实世界,实现对系统的实时感知和故障预测。Zhao等^[11]将数字孪生技术引入车辆软件定义网络,以自适应的方式对车辆网络中的方案进行迭代,提高网络的系统效率和性能。Pan等^[12]基于数字孪生,提出了一种数字双驱动的决策信息体系结构,以解决工业园区内车辆获取货物并搬运的动态性问题,并进行了相关案例研究,具有一定的可行性和有效性。

虽然上述研究在数字孪生和交通结合领域做出了相关尝试,但是其中很大一部分仅从个体出发,未考虑系统层面,而剩余的研究仅进行了感知和预测,并未将其与决策相结合以提升决策能力。事实上,多车协同感知决策能够有效提升路网效率^[13],在数字孪生中,仿真、建模、分析和辅助决策都是重点,侧重的是物理世界对象在数据世界的重现、分析、决策及反馈^[14]。如果将交通流预测中对时空特征的挖掘能力和深度强化学习的决策能力相结合^[15],并放入数字孪生的框架中,提升感知、预测、决策能力,就能够优化城市交通流导引的系统性,缓解交通压力。

2 基于数字孪生的智能交通流预测与导引

数字孪生作为一种新兴技术,实现了物理世界和虚拟映射间的数字化反馈。本节介绍了基于数字孪生的分层时空交通流预测与导引系统模型,该模型从宏观和微观两个角度对城市交通系统进行映射,并在虚拟空间内实现上层预测到下层决策的数据传输与转化,构建从城市真实道路到虚拟拓扑、再从虚拟车辆到真实车辆的完整生命周期。

2.1 系统模型

为了提升交通流预测与导引的效率,本文提出一种基于数字孪生的城市智能交通流预测与导引框架,并引出分层孪生的概念,如图1所示。

分层数字孪生结构主体包括道路孪生和车辆孪生,虚拟空间上层为道路孪生,下层为车辆孪生。其中,道路孪生部署于中央服务器上,以图的形式对真实道路拓扑建立孪生,预测未来时空流量数据,在该层中,城市交通状况以宏观交通流的形式存在。车辆孪生则部署在车辆实体上,以微观个体的形式存在,在虚拟空间中对车辆进行本地建模,并以深度强化学习的方式进行自我学习和决策。

上下两层孪生分别对应城市交通中不同的真实物理实体,虽然二者的虚拟映射存在于不同的信息平台中,但它们具有一定的耦合关系。首先,分层的孪生从两个不同的角度对城市交通进行建模,全方位增强对于城市交通的感知能力,其次,上层的道路孪生根据感知信息挖掘时空流动性,对交通流流量进行精准预测,增强了对于未来路况的预测能力。除此之外,车辆孪生通过深度强

化学习进行决策时所依赖的信息不仅包括车辆本身的出行需求和周遭感知,还包括上层道路孪生对于路况显式的判断,极大地增强了车辆的协同决策能力。不同层次的虚拟映射之间通过简单的信息交互就能够实现微观与宏观、车辆与交通流之间时空特征的转换,提高交通预测与导引效率。

2.2 问题描述

定义城市为一个有向图 $G(D, E)$,其中 D 为城市道路中各个路($d_1, d_2, \dots, d_n, n \in N$)的集合, E 为连接各个路口 d_i, d_j 的道路 e_{ij} 集合。对于城市道路中的路况,本文用 x_t^{ij} 表示 t 时刻道路 e_{ij} 流量状态,并将 t 时刻所有道路的流量表示为向量 $\mathbf{X}'$ 。此外,对于 t 时刻城市道路中的车辆,用集合 $\mathbf{C}' = (c_1, c_2, \dots, c_n)$ 表示,由于车辆在到达目的地后就会消失,且会不断产生新的出行需求,因此 $\mathbf{C}'$ 是一个动态集合。集合中的车辆具有多种属性,包括车辆类型、当前位置、目的地所在位置等,本文将车辆 c_i 的所有属性表示为向量 $\mathbf{F}_i$ 。

因此,本文将研究转化为两个问题。

问题1 对于道路状态,可以将问题描述为:已知过去时段 τ 内城市道路中各条道路的流量状




图1 基于数字孪生的城市智能交通流预测与导引框架



态 $(X^{t-T_p}, X^{t+1-T_p}, \dots, X^{t-1}, X^t)$, 预测未来 T_p 时段内这些道路的流量状态 $(X_i^{t+1}, X_i^{t+2}, \dots, X_i^{t+T_f})$ 。

问题 2 对于车辆个体, 是已知 t 时刻车辆集合 C' 内即将到达路口的车辆、各车辆的属性向量 F_i 以及各个道路未来 T_p 时段内的流量状态, 求解车辆到下一路口时应选择的方向, 从而提高系统整体的出行效率。

由于现实世界中无法实现预测模型和决策模型根据城市交通状况的实时更新, 因此, 本文引入数字孪生, 根据感知的路况信息不断更新预测和决策模型, 同时实现预测信息从中央服务器到车辆个体的实时传递, 辅助车辆进行决策选出最优策略。将城市道路在数字孪生所对应的虚拟映射定义为 $\hat{G}(\hat{D}, \hat{E}) = G(D, E)$, 同样车辆集合的底层映射 $\hat{C}' = C'$, 并将其属性进行实时采集和建模, 在虚拟空间内不断求解上述两个问题, 并将结果反馈于物理世界。

3 具有时空流动性的交通流预测与导引

本节在虚拟空间内部对上述问题进行依次求解。在上层道路孪生, 应用了基于扩散卷积的时空交通流预测方法, 充分挖掘交通流数据的时空特征。在下层车辆孪生, 则将上层预测数据显式作用于深度强化学习, 并设计差异化协同奖励值, 实现虚拟空间中车辆的时空协同性决策。

3.1 基于扩散卷积的时空交通流预测

扩散卷积 (diffusion convolution) 是一种较为经典的时空交通流预测方法, 它将车辆的移动看作分子的随机游走过程, 从而捕捉交通的动态性和时空依赖性。

经典的扩散过程主要包括两种元素: 一种是重启概率 $\alpha \in [0, 1]$, 另一种则是状态转移矩阵 $D_o^{-1}W \in \mathbf{R}^{N \times N}$, 其中 $D_o = \text{diag}(W)$ 表示出度对角矩阵, W 则是加权邻接矩阵, 用于描述节点之间的相邻关系, 从而通过计算可以得出扩散趋于稳定时的状态转移分布:

$$P = \sum_{k=0}^{\infty} \alpha(1-\alpha)^k (D_o^{-1}W)^k \quad (1)$$

其中, k 为扩散的步数。

由于城市交通中车辆的扩散是一个相互的过程, 需要考虑双向传播, 上述的状态转移矩阵改写为 $D_o^{-1}W$ 和 $D_l^{-1}W^T$ 分别来描述正向和逆向的扩散过程, 再根据上述的状态转移分布, 进而可以获得经典的扩散卷积层表达:

$$X_{:,q} = a \left(\sum_{p=1}^P \sum_{k=0}^{K-1} (\theta_1 (D_o^{-1}W)^k + \theta_2 (D_l^{-1}W^T)^k) X_{:,p} \right), \quad (2)$$

$q \in 1, \dots, Q$

其中, $X_{:,p} \in \mathbf{R}^{N \times P}$ 为每个点的嵌入向量长度为 P 的图信号输入, $\theta_1, \theta_2 \in \mathbf{R}^{Q \times P \times K}$ 分别为正向和逆向扩散的滤波器参数, a 为激活函数, $X_{:,q} \in \mathbf{R}^{N \times Q}$ 为每个点的嵌入向量长度为 Q 的图信号输出。

为了同时关注交通流的时间相关性, 本文选用门递归单元捕捉时间相关性, 扩散卷积过程替代门递归单元中的乘法单元, 获得扩散卷积递归神经网络, 如图 2 所示。最后, 使用序列模型实现多步预测^[16]。




图 2 扩散卷积递归神经网络

3.2 基于深度强化学习的时空协同交通流导引方法

在交通流导引问题上, 由于城市交通动态性强且具有大量的微观信息, 因此状态空间数量非常大, 经典的强化学习方法 Q 学习^[17]方法不能应用于此。又因为城市道路中海量的车辆数目, 多智能体强化学习^[18]所带来的巨大计算开销同样难以承担, 所以本文将需要决策的车辆看作单个智能体, 其余车辆的驾驶行为和整体路网作为动态

环境,使用深度强化学习进行协同决策。

深度强化 Q 学习 (deep reinforcement Q -learning) 是深度学习和强化学习结合的典范,它既具有强化学习的环境交互、决策能力,同时又通过深度神经网络来拟合 Q 值,具有强大的信息挖掘能力。

本文所使用的深度强化 Q 学习方法是 2015 年年初 Deepmind 在 *Nature* 上所发表的^[19],它引入了目标网络和评估网络,并共享相同的网络结构,评估网络以一定频率更新目标网络,从而维持算法的稳定性,同时,使用经验回放池消除数据相关性。

在深度强化 Q 学习中,状态 s 被看作神经网络的输入,通过神经网络后获得不同动作对应的 Q 值,可以认为是不同动作的好坏程度。深度强化 Q 学习的损失函数如下。

$$L(\omega) = E \left[\left(R + \gamma \cdot \max_a \hat{Q}(s', a'; \omega^-) - Q(s, a; \omega) \right)^2 \right] \quad (3)$$

其中, R 是当前动作的奖励值, Q 代表评估 Q 网络的动作值函数, $\hat{Q}$ 则表示目标网络的动作值函数, ω^- 、 ω 分别为两个网络的参数。

为了优化网络从而对策略进行拟合,需要进行反向传播,过程如下。

$$\frac{\partial L(\omega)}{\partial \omega} = E \left[\left(R + \gamma \cdot \max_a \hat{Q}(s', a'; \omega^-) - Q(s, a; \omega) \right) \frac{\partial Q(s, a; \omega)}{\partial \omega} \right] \quad (4)$$

接下来将分别对状态、动作、奖励值和算法流程进行介绍。

(1) 状态定义

状态设计是城市交通流导引中的关键问题,为了实现车辆从起点到终点的行驶,首先需要对位置信息进行描述。然而字符或数字信息无法对不同的道路进行区分,因此本文首先通过独热编码^[20],用 N 位状态寄存器来对 N 条道路进行编码,每条道路都有其独立的寄存器位,并且在任意时候,其中只

有一位有效,把车辆 t 时刻的当前位置和目的地位置编码进行拼接,作为位置信息 S_t^l 。其次,将车辆感知、实时路况和上层孪生预测的未来时段路况作为预测信息 S_t^f ,最后,将信息进行拼接获得状态 S_t 。

(2) 动作定义

对于智能体车辆而言,需要根据当前状态选择一个合适的动作 a_t ,然而车辆在不同路口和行驶方向都使用相同的神经网络输出的动作,为了提升模型的泛化能力,我们需要用具体的道路编号取缔简单的方向作为输出。因此,目标网络评估车辆当前行驶到所有道路的对应 Q 值,再根据可达性,取其相邻道路中 Q 值最大者作为动作输出。

(3) 奖励值定义

车辆在 t 时刻的状态为 S_t ,通过神经网络决策后输出的动作为 a_t ,车辆在执行动作后将获得一个奖励值 r_t ,用于评估该动作的好坏,并将之存入经验回访池中,进一步更新网络参数。为了通过深度强化 Q 学习实现车辆的协同系统级决策,奖励值设定是最为重要的一环。因为普通的奖励值设定通常会让车辆只顾及自己的利益,而忽略动作对未来路况的影响^[21]。

本文提出一种基于优先级的协同奖励值设计方法,用于实现在深度强化学习环境下大规模智能体的差异化协同。本文将奖励值分为两个层次,一个是对于车辆的决策对自身而言所带来影响的 r_t^{self} ,另一个则是车辆的决策对周围未来路况所带来的影响 r_t^{system} 。两者加权得到状态 S_t ,动作 a_t 所对应的奖励值:

$$r_t = \alpha r_t^{\text{self}} + \beta r_t^{\text{system}} \quad (5)$$

其中, α 、 β 分别为两者的权值,针对不同的车辆个体,可以更改权值从而协调车辆在系统中的优先级,从而实现系统内车辆的差异化协作。

3.3 多智能体时空协作深度强化学习算法

本文所提多智能体时空协作深度强化学习 (ST-DQN) 算法使用车辆决策改进的扩散卷积捕捉空间相关性,并结合门控循环单元模型捕捉时间相关



性,将预测结果作为车辆状态输入深度神经网络,进行策略拟合,同时,由于车辆决策的动作实施需要时间,因此将输出决策再次放入预测模型进行迭代,评估动作质量计算奖励值。算法 1 如下。

算法 1 时空协同深度强化学习 (ST-DQN) 算法

初始化目标网络 $\hat{Q}$ 、评估网络 Q 、DCRNN 预测网络,建立孪生

for episode=1, M **do**:

初始化路网环境 $\dot{G}(\dot{D}, \dot{E})$, 采集历史流量信息

for $t=1, T$ **do**:

输入历史流量信息 $\mathbf{X}^{t-T_p}, \mathbf{X}^{t+1-T_p}, \dots, \mathbf{X}^{t-1}, \mathbf{X}^t$

DCRNN 预测未来时段路网流量 $\mathbf{X}_i^{t+1}, \mathbf{X}_i^{t+2}, \dots, \mathbf{X}_i^{t+T_f}$

for car in $\dot{C}^t$:

筛选需要决策的车辆,如果车辆即将到达路口:

选择动作 $a_t = \max_a Q(s_t, a; \omega)$

end for

输出所有车辆动作并根据预测路况评估对应动作奖励值

将 (S_t, a_t, r_t, S'_t) 存入经验回访池中

随机采样反向传播更新评估网络

输出决策作用于物理世界

更新 DCRNN 预测网络

end for

一定时间间隔用评估网络 Q 更新目标网络 $\hat{Q}$

end for

相比传统的深度强化 Q 学习,本文所提算法主要有 3 点改进:首先是奖励值的设定,通过基于优先级的奖励值使车辆实现差异化协作,增强了车辆决策的系统性;其次是车辆进行决策时所依赖的状态,不仅是马尔可夫过程的当前状态,还包括对未来时空交通流量的预测,增强时空依赖,提升了车辆决策的长远性;最后,借助数字孪生的框架实现模型的在线更新,不断优化决策过程,提高学习效率。

4 仿真性能评估


本节对仿真场景进行描述,并对算法性能进行相关评估。

4.1 仿真环境设计


本文仿真所使用的真实世界选用 SUMO 进行实现^[22],虚拟映射则使用 Torch 深度学习框架进行建模。SUMO 是一个开源、高度便携、微观和连续的多模式交通模拟软件包,旨在处理大型交通网络。

仿真场景示意图如图 3 所示。图 3 (a) 中,仿真使用 4×4 的曼哈顿地图,每条边长 200 m,都有正向和反向两个车道。从仿真开始每 0.6 s 产生一辆车辆,具有随机的起点和目的地,同时,本文限制了车辆的最短旅行长度为 1 km,以保证每辆车都会至少进行 5 次决策。

图 3 (b) 为仿真十字路口及车辆示意图,在每个车道的邻近末尾的 30 m 处设置感知器,用于监测道路的流量状况和预先选择要决策的车辆并预留出迭代时间, SUMO 中的车辆可以模拟真实驾驶,并能够具体设置跟车、换道等动力学模型。



(a) 仿真全景地图



(b) 十字路口及车辆示意图

图 3 仿真场景示意图

仿真中使用的车辆为同一类型, 仿真车辆参数见表 1。

表 1 仿真车辆参数

参数	取值
加速度/($\text{m}\cdot\text{s}^{-2}$)	2.6
减速度/($\text{m}\cdot\text{s}^{-2}$)	4.5
车辆长度/m	5.0
最大速度/($\text{km}\cdot\text{h}^{-1}$)	200
跟车模型	Krauss

在建立道路孪生和车辆孪生后, 通过接口 Traci 实时读取路网、车辆速度、位置等信息用于更新模型, 以保证虚拟映射与物理实体的高度一致性。

4.2 仿真结果比较与分析

首先对本文所提算法的收敛性和稳定性进行评估, 接下来从多个方面比较所提算法对城市交通拥堵的缓解作用, 包括不同交通状况下出行的达成率, 车辆在出行途中的拥堵时间以及车辆实际行驶距离与最短距离的比值分布。此外, 本文加入了迪杰斯特拉 (Dijkstra) 最短路径算法、随机 (Random) 算法以及仅考虑自身利益的传统深度强化学习 (DQN) 方法进行对比分析。

图 4 展示了训练过程中奖励值大小, 可以看到, 本算法具有较好的收敛性与稳定性, 在训练约 200 轮后展现收敛态势。




图 4 算法收敛性

车辆出行达成数量如图 5 所示, 比较了 4 种

不同算法下车辆出行的达成数量, 由于仿真中车辆生成概率一定, 如果车辆到达率较低, 则随着时间增加, 路网中将会积累更多车辆, 从而加剧拥堵。结果显示, 在未产生拥堵时, 各算法对交通导引能力相近, 但随着时间的流逝和车辆数目的增长, 本文所提算法保持良好的疏导能力, 车辆始终能够维持较高的到达率, 而其余 3 种算法在产生一定拥堵后的车辆到达率都有明显下降。




图 5 车辆出行达成数量

不同负载下的平均等待时间如图 6 所示, 比较了 4 种不同算法下随路网负载增加, 车辆平均拥堵时长的变化。本文所提算法在车辆数量增多的情况下, 车辆平均拥堵时长略有增长, 但远小于其余算法的增长率, 因此, 相对于现有传统算法, 本文所提具有更强的道路容纳能力。




图 6 不同负载下的平均等待时间



实际出行距离与最短距离比值概率分布如图 7 所示,展示了本算法下车辆实际行驶距离与最短距离之间比例的概率分布,近 80%的车辆并没有绕行行为,剩余车辆绕行距离也集中在出行距离的 20%~30%,结果显示本算法能够在减缓交通拥堵的同时,尽量权衡个体与系统间的出行利益,不会通过大量牺牲某些个体的自身利益来提高系统出行效率。




图 7 实际出行距离与最短距离比值概率分布

5 结束语

本文针对传统交通流导引中忽略时空相关性,提出了基于数字孪生的城市智能时空交通流预测与导引框架,引入分层孪生的概念,分别对道路拓扑和车辆个体建立虚拟映射,通过扩散卷积递归网络在道路孪生捕捉时空依赖,并作为状态输入车辆孪生,结合深度强化学习实现差异化智能体时空协同决策。基于 SUMO 仿真平台模拟城市交通系统,对所提算法进行仿真验证,并与经典算法进行比较。实验结果表明,所提框架及算法能有效减少城市交通拥堵,权衡个体与系统出行利益,实现车辆协同的长远性决策。

参考文献:

[1] 齐旭. 车路协同系统: 解决交通拥堵是目的[N]. 中国电子报, 2021-10-01(7).

QI X. Vehicle-road collaboration system: solving traffic congestion is the goal[N]. China Electronics News, 2021-10-01(7).

[2] RAHIMI-FARAHANI H, RASSAFI A A, MIRBAHA B. Forced-node route guidance system: incorporating both user equilibrium and system optimal benefits[J]. IET Intelligent Transport Systems, 2019, 13(12): 1851-1859.

[3] LI Y, YU R, SHAHABI C, et al. Diffusion convolutional recurrent neural network: Data-driven traffic forecasting[J]. arXiv preprint arXiv:1707.01926, 2017.

[4] GUO S N, LIN Y F, FENG N, et al. Attention based spatial-temporal graph convolutional networks for traffic flow forecasting[C]//Proceedings of the AAAI Conference on Artificial Intelligence[S.l.:s.n.], 2019: 922-929.

[5] JIANG M R, CHEN W, LI X. S-GCN-GRU-NN: a novel hybrid model by combining a spatiotemporal graph convolutional network and a gated recurrent units neural network for short-term traffic speed forecasting[J]. Journal of Data, Information and Management, 2021, 3(1): 1-20.

[6] PIASCIK R, VICKERS J, LOWRY D, et al. Technology area 12: materials, structures, mechanical systems, and manufacturing road map[J]. NASA Office of Chief Technologist, 2010: 15-88.

[7] BRUNNER P, DENK F, HUBER W, et al. Virtual safety performance assessment for automated driving in complex urban traffic scenarios[C]//Proceedings of 2019 IEEE Intelligent Transportation Systems Conference (ITSC). Piscataway: IEEE Press, 2019: 679-685.

[8] HU C, FAN W C, ZENG E, et al. Digital twin-assisted real-time traffic data prediction method for 5g-enabled Internet of vehicles[J]. IEEE Transactions on Industrial Informatics, 2022, 18(4): 2811-2819.

[9] ALAM K M, EL SADDIK A. C2PS: a digital twin architecture reference model for the cloud-based cyber-physical systems[J]. IEEE Access, 2017(5): 2050-2062.

[10] DU W J, ZHANG T F, ZHANG G G, et al. A digital twin framework and an implementation method for urban rail transit[C]//Proceedings of 2021 Global Reliability and Prognostics and Health Management (PHM-Nanjing). Piscataway: IEEE Press, 2021: 1-4.

[11] ZHAO L, HAN G J, LI Z H, et al. Intelligent digital twin-based software-defined vehicular networks[J]. IEEE Network, 2020, 34(5): 178-184.

[12] PAN Y H, WU N Q, QU T, et al. Digital-twin-driven production logistics synchronization system for vehicle routing problems with pick-up and delivery in industrial park[J]. International Journal of Computer Integrated Manufacturing, 2021, 34(7/8): 814-828.


[13] 曹佳钰, 冷甦鹏, 张科. 面向自动驾驶应用的车联多智能体

- 信息融合协同决策机制研究[J]. 物联网学报, 2020, 4(3): 69-77.
- CAO J Y, LENG S P, ZHANG K. Multi-agent driven collaborative decision mechanism of information fusion for autonomous driving vehicles[J]. Chinese Journal on Internet of Things, 2020, 4(3):69-77.
- [14] 詹全. 闭环数字孪生智慧交通管理系统[J]. 中国交通信息化, 2021(10): 107-109.
- ZHAN Q. Closed-loop digital twin intelligent traffic management system[J]. China ITS Journal, 2021(10): 107-109.
- [15] 康宇, 刘雅琼, 赵彤雨, 等. AI 算法在车联网通信与计算中的应用综述[J]. 电信科学, 2023, 39(1): 1-19.
- KANG Y, LIU Y Q, ZHAO T Y, et al. A survey on AI algorithms applied in communication and computation in Internet of vehicles[J]. Telecommunications Science, 2023, 39(1):1-19.
- [16] ROZEMBERCZKI B, SCHERER P, HE Y X, et al. PyTorch geometric temporal: spatiotemporal signal processing with neural machine learning models[C]//Proceedings of the 30th ACM International Conference on Information & Knowledge Management. New York: ACM Press, 2021: 4564-4573.
- [17] NAHUM-SHANI I, QIAN M, ALMIRALL D, et al. Q-learning: a data analysis method for constructing adaptive interventions[J]. Psychological Methods, 2012, 17(4): 478-494.
- [18] LOWE R, WU Y, TAMAR A, et al. Multi-agent actor-critic for mixed cooperative-competitive environments[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. New York: ACM Press, 2017: 6382-6393.
- [19] MNIH V, KAVUKCUOGLU K, SILVER D, et al. Human-level control through deep reinforcement learning[J]. Nature, 2015, 518(7540): 529-533.
- [20] 唐慕尧, 周大可, 李涛. 结合状态预测的深度强化学习交通信号控制[J]. 计算机应用研究, 2022: 1-6. doi:10.19734/j. issn. 1001-3695.2021.12.0704.
- TANG M Y, ZHOU D K, LI T. Deep reinforcement learning traffic signal control combined with state prediction[J]. Application Research of Computers, 2022: 1-6. doi:10.19734/j.issn. 1001-3695.2021.12.0704.
- [21] PENG Z, LI Q, HUI K M, et al. Learning to simulate self-driven particles system with coordinated policy optimization[J].


Advances in Neural Information Processing Systems, 2021(34): 10784-10797.

- [22] LOPEZ P A, BEHRISCH M, BIEKER-WALZ L, et al. Microscopic traffic simulation using SUMO[C]//Proceedings of 2018 21st International Conference on Intelligent Transportation Systems (ITSC). Piscataway: IEEE Press, 2018: 2575-2582.

[作者简介]



廖熙雯（1998—），女，电子科技大学信息与通信工程学院博士生，主要研究方向为无线通信、交通路网与车联网协同优化。



冷甦鹏（1973—），男，电子科技大学教授、博士生导师，主要研究方向为物联网、车联网、新一代宽带无线网络、无线自组织网、智能交通信息系统的资源管理、介质访问控制、路由、组网与互联、智能算法理论及技术应用等。



明昱君（1999—），女，电子科技大学信息与通信工程学院硕士生，主要研究方向为无线网络及智能优化、交通路网与车联网。



李天扬（1997—），女，电子科技大学信息与通信工程学院博士生，主要研究方向为无人机网络。