

网联共享车路协同智能交通系统综述

郭 戈^{1,2,3†}, 许阳光², 徐 涛³, 李丹丹², 王云鹏⁴, 袁 威³

(1. 东北大学 流程工业综合自动化国家重点实验室, 沈阳 110004; 2. 大连海事大学 自动化系, 辽宁 大连 116026; 3. 东北大学秦皇岛分校 控制工程学院, 河北 秦皇岛 066004; 4. 大连理工大学 控制科学与工程学院, 辽宁 大连 116024)

摘 要: 网联车辆、交通大数据、共享出行等技术给智能交通系统的发展与应用革新带来了机遇和挑战. 在全面总结共享出行系统、网联车辆协同优化控制、交通大数据分析等领域最新研究成果的基础上, 系统论述智能交通技术的研究进展, 特别对智能交通系统中的交通流及出行需求预测、共享出行系统车辆调度、交通网及电网联合优化、网联车辆协同控制及车-路协同控制等方面进行全面综述. 分析智能交通系统存在的问题及挑战, 并对其未来发展方向进行展望.

关键词: 智能交通; 大数据; 共享出行; 交通预测; 车辆调度; 车辆协同控制

中图分类号: TP273; U12 **文献标志码:** A

A survey of connected shared vehicle-road cooperative intelligent transportation systems

GUO Ge^{1,2,3†}, XU Yang-guang², XU Tao³, LI Dan-dan², WANG Yun-peng⁴, YUAN Wei³

(1. State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University, Shenyang 110004, China; 2. Department of Automation, Dalian Maritime University, Dalian 116026, China; 3. School of Control Engineering, Northeastern University at Qinhuangdao, Qinhuangdao 066004, China; 4. School of Control Science and Engineering, Dalian University of Technology, Dalian 116024, China)

Abstract: Connected vehicles, big traffic data, car-sharing and other technologies provide opportunities and challenges to the development and application innovation of intelligent transportation systems (ITS). Based on a comprehensive summary of the latest research results in the fields of car-sharing systems, collaborative optimal control of connected vehicles, traffic data analysis and so on, a systematic survey of the research progress of intelligent transportation technologies is proposed, especially, a comprehensive review is made from prespectives of traffic flow and travel demand prediction, vehicle dispatching of mobility-on-demand systems, joint optimization of transportation network and power grid, cooperative control of connected vehicles and vehicle-road collaborative control. The existing problems and challenges of ITS are summarized, showing the promising development directions for future research.

Keywords: intelligent transportation; big data; car-sharing; traffic forecasting; vehicle scheduling; vehicle collaborative control

0 引 言

随着物流和运输业的快速发展和汽车保有量的迅速增长, 道路交通系统承载的各类车辆及人员/货物运输达到空前规模, 导致严重的交通拥堵和环境污染以及巨额成本, 也给交通系统带来严峻的挑战, 迫切需要高效率、低能耗、低成本的新型交通出行模式和运行优化技术. 智能交通系统基于先进的检测、计算、通讯、控制及管理技术, 可为交通主体和出行者提供全面及时的信息, 提高交通出行的效率和安全性, 是解决上述问题的有效途径.

智能交通系统发展分 4 个阶段: 第 1 阶段是提升道路等级和路网容量, 发展包括快速公交、常规公交、轨道交通(轻轨、地铁)、单车在内的多种交通模式, 增加公共交通运力. 第 2 阶段是优化交通管理, 提高效率, 减少拥堵, 例如, 很多城市采取限号行驶措施, 可缓解交通拥堵和空气污染问题. 第 3 阶段是用新能源车辆替代燃油车辆, 发展绿色交通技术, 解决燃油依赖和空气污染问题. 各国正在普及电动车及配套设, 电动车在速度要求不高的应用领域优势明显^[1], 已在公共交通及通勤、网约车、共享汽车、快递及

收稿日期: 2019-09-19; 修回日期: 2019-10-10.

基金项目: 国家自然科学基金项目(61573077, U1808205).

†通讯作者. E-mail: geguo@yeah.net.

最后一公里物流等领域逐步取代燃油车. 近年来, 智能交通系统进入了新的发展阶段, 其主要特点是: 1) 引入网联车辆构建智能车路系统, 提高交通容量和出行效率; 2) 发展共享汽车及服务技术, 形成基于新能源共享车辆的按需出行系统, 替代传统出行方式, 控制汽车保有量; 3) 借助交通大数据, 挖掘和预测交通出行系统的时空规律, 提升交通出行的可预期性, 优化交通网络及其车辆部署和运行. 目前, 智能交通系统正在向网联共享、数据赋能、车路协同、按需出行方向发展, 有望形成以智慧道路、网联车、大数据等为基础的新一代智能交通系统.

本文在全面综述共享出行系统、网联车辆协同控制、交通大数据分析等领域的最新研究成果的基础上, 通过系统论述智能交通系统研究的进展和存在的理论与技术挑战, 对未来发展前景进行了展望.

1 大数据驱动的交通预测

随着电磁线圈、视频监控、车载GPS、手机和移动互联网等技术的广泛使用, 反应交通和出行状态的数据快速增长, 交通系统进入了随时随地可预期的大数据时代. 人们可以准确及时地了解交通信息、出行需求信息、车辆行驶轨迹和人员出行规律, 为交通系统的优化部署和运行、缓解交通拥堵提供了有力支持. 但是, 交通数据体量大、空间覆盖广、观测周期长、实时性强, 通过海量数据理解交通和出行规律极其困难. 目前的研究主要集中在交通数据分析、交通流预测和出行需求预测等方面.

1.1 交通事故的分析与预测

理解交通事故发生的原因并对可能发生的事故做出预警, 对制定有效的交通管理方案至关重要. 同时, 基于大数据的交通系统实时响应性能分析, 有助于提高事故应急救援能力、减少事故持续时间及其影响. 关于交通事故与司机行为、天气和路况等因素的关系研究已有不少结果. 比如, 文献[2]基于实测交通流数据和多元统计模型, 研究了城市快速路发生的交通事故与天气、光照条件、交通流量等因素之间的关系, 指出天气和照明条件可通过影响交通流和交通速度进而直接或间接地导致交通事故; 文献[3]采用多元逻辑回归算法对碰撞及车辆特性对驾驶员死亡风险的影响做了研究. 由于交通事故本身的固有特点, 许多因素的关系无法简单量化, 而且, 随着事故数据容量的扩大, 对算法的计算速度和精度要求越来越高, 上述方法很难准确揭示不同因素对交通事故风险的影响.

近年来, 基于深度学习的交通事故实时预测成为新的研究热点. 文献[4]基于历史交通事故数据和深度学习中的深度堆栈去噪自编码器, 给出了一种行人活动对交通事故风险的预测方法. 不过, 现有方法未考虑交通流量、天气条件、起讫数据等重要因素, 仅靠人类活动的数据建立事故风险预测模型, 预测结果不够可靠, 有必要综合多种因素构建预测模型, 以提高交通事故风险预测能力. 为此, 文献[5]基于一种可捕捉事故频率的时空分布与各因素的深层联系的深度学习模型, 提出了一种高精度交通事故风险预测方法.

1.2 交通排放估计

常见的交通排放估计模型分为宏观模型和微观模型, 其中宏观模型根据交通网络的总流量和平均车速计算排放^[6], 微观模型侧重估计单个路段、特定车型的尾气排放. 微观模型一般较宏观模型更为准确, 但生成微观模型的输入数据耗时长, 且不适用于大范围排放分析与估计^[7]. 基于大数据的交通排放估计可获得更大范围、更准确的估计结果, 也不依赖于微观模拟实验^[8], 文献[9]给出一种基于GPS数据测量道路车辆排放分布的方法, 进而制定了机动车排放清单. 文献[10]运用大数据挖掘技术, 给出一种从出租车实时轨迹数据中提取出租车出行模式的方法, 进而分析了以混合动力汽车替代化石燃料出租车对温室气体排放的影响. 上述文献未研究燃料消耗和排放模式的空间-时间分布特征, 为此, 文献[11]利用实时行驶轨迹数据集研究了出行模式与车辆排放的时空分布特征, 发现尾气排放的时空分布显著不同于出行模式和能源消耗, 在空间上呈双核环状分布. 已有文献主要研究单一交通模式下的排放分布, 而多模式综合交通系统的排放估计问题值得进一步研究.

1.3 交通流预测

交通流预测是智能交通系统的重要研究领域之一, 对交通管理和诱导、提升出行效率具有重要意义. 传统交通流预测方法主要有时间序列法^[12]、卡尔曼滤波法^[13]、支持向量机回归法、 K 近邻法^[14]、机器学习法^[15]和人工神经网络^[16]等. 基于时间序列的交通流预测方法应用广泛, 其中时间序列模型分为线性平稳模型和非线性平稳模型. 线性模型包括自回归模型(AR)、滑动平均模型(MA)和自回归滑动平均模型(ARMA)等; 非线性模型中最常见的是基于自回归混合滑动平均模型(ARIMA)^[17]的预测方法. 需要指出的是, 基于时间序列的交通流预测方法通常

假设时间序列的方差不变,而实际时间序列方差是变化的,且这类方法需要复杂的参数估计,影响交通流的预测精度.为提高预测性能,可采用人工神经网络、机器学习等方法,也可将这些方法与时间序列方法相结合形成混合预测方法,比如不同的时间序列模型与人工神经网络模型相结合形成各种混合模型^[18-19].

传统的交通预测模型简单实用,但不适合处理海量交通数据,也无法捕获交通数据中的复杂时空特性,大量高维数据输入还很容易给传统方法带来维数灾难问题.近年来,深度学习在交通大数据挖掘方面得到应用,尤其深度网络结构能获取数据的高层特征,给交通流预测提供了新的有效手段.例如,文献[20]利用深度自编码器预测交通流,证明深度模型预

测交通流比较有效,但由于无监督学习模型的局限性,预测精度不够高.文献[21]提出基于递归神经网络(RNN)预测交通流,但存在梯度消失和梯度爆炸问题,无法精确用于长期时间序列的建模.交通流预测的关键问题是同时捕获交通数据的时间、空间特性以及时空相关性,研究人员在这方面做了大量工作,文献[22]将交通流视为图像输入,采用卷积神经网络(CNN)解决交通流预测问题.这两种方法对交通流时间维信息的处理能力不足,因此,文献[23]提出融合卷积神经网络和长短期记忆网络(Conv-LSTM),用于捕获交通数据的时空相关性,文献[24]融合图卷积和时间卷积网络进行交通流预测,都取得了良好的预测性能.不同交通流预测模型的对比见表1.

表2 交通流预测模型对比

模型	优点	缺点
ARIMA	计算简单,速度快	线性模型,未考虑空间特性;无法添加非交通量数据
SARIMA	计算简单,速度快,能够消除季节因素	线性模型,未考虑空间特性;无法添加非交通量数据
STARIMA	计算简单,速度快,能描述时空特性	线性模型,无法添加非交通量数据
ARIMAX	计算简单,速度快,能添加非交通量数据	线性模型,未考虑空间特性.
卡尔曼滤波器	结构简单	线性模型,未考虑空间特性;无法添加非交通量数据
贝叶斯网络	非线性模型,能描述时空特性	不能添加非交通量数据
K近邻	非线性模型,能描述时空特性,含非交通量数据	需要确定最优的K值
前馈神经网络	非线性模型,含非交通量数据	训练复杂,易过拟合,不能精确描述时空特性
递归神经网络	含非交通量数据,非线性模型	未考虑空间特性,训练复杂,易过拟合
卷积神经网络	含非交通量数据,非线性模型	训练复杂,易过拟合,不能精确描述时空特性
CNN+LSTM	含非交通量数据,非线性模型,较好描述时空特性	训练复杂,易过拟合,未考虑路网的拓扑结构
GCN+LSTM	含非交通量数据,非线性模型,较好描述时空特性,考虑路网拓扑	训练复杂,易过拟合

1.4 出行需求预测

出行需求预测对提高交通系统运行效率至关重要,是另一个研究热点.出行需求预测的是时变的乘客出发地和目的地集合,实际中可能还包含出发地与目的地间的道路、行驶时间等信息.出行需求通常与前几小时、前几天同一时间段及所在区域的特性密切相关,变量多、数据量庞大.因此,相较于交通流预测,出行需求预测更具挑战性,需要更强的实时性和更高的细粒度,因为出行需求的出发地与目的地有更强的时间依赖性、空间依赖性以及外源依赖性.

常见的出行需求预测模型包括统计方法、时间序列方法、深度学习模型.统计方法(如贝叶斯方法^[25]、马尔科夫方法^[26]等)能以较低的运算和实施成本实现快速准确的预测,但精度不够,处理复杂历

史数据时空特性的能力不强.基于时间序列的出行需求预测方法(如ARIMA和SARIMA等)忽略了空间依赖性^[27],而出行需求具有多变的时空特性,因此这种方法只适用于单个断面、单条道路等简单情景,难以在数据量大的复杂应用场取得满意性能.有些研究结合聚类算法、无监督学习等方法,对时间序列方法进行改进,例如文献[28]提出一种多视图聚类算法,利用无监督模型预测出行需求,由于出行数据量很大,这些方法计算非常复杂,性能不理想.

近年来,深度学习方法也被用来解决出行需求预测问题,成为研究热点^[29],出现了残差网络模型^[30]、循环网络模型^[31]、卷积网络和循环网路混合模型^[32]等多种需求预测模型.现有研究多侧重于公共交通网络的日常出行需求变化,文献[33]考虑公共交通网

络日常出行需求的内部时间和空间相关性,提出了DNN模型的预测方法;随着共享汽车和按需出行模式的兴起,也有文献研究按需出行服务等新型交通系统的需求预测问题,文献[32]针对按需出行系统的短期乘客需求预测问题,综合考虑出行需求的空间、时间和外部依赖性,提出一种融合卷积长短期记忆网络(FCL-Net)深度学习方法,能较好地捕捉时空特征与外部变量的相关性,实现精确的出行需求预测;文献[34]提出一种基于卷积长短期记忆(Conv-LSTM)网络和端到端学习的出行需求预测方法,将历史旅行数据作为网络模型的视频流输入,通过提取数据的时空特性,实现准确有效的出行需求预测。但是,这一类模型仍面临着过拟合、欠拟合以及需要手动调节的超参数等众多问题。

2 基于共享汽车的按需出行系统

基于共享车辆的按需出行系统是城市交通出行的一种新模式。按需出行系统采用小型电动汽车和共享出行方式,可降低非再生能源依赖和污染,系统运行优化调度更为灵活、高效和安全。由于车辆和出行需求数量庞大,时空分布特性动态变化,且受公共交通、车辆停泊站点及续航能力等限制,这种系统面临动态任务分配及车辆调度、运行优化与再平衡等难题^[35-39]。

2.1 车辆运行调度与系统再平衡

2.1.1 车辆运行调度

如何让恰当的车辆在恰当的地点和时间服务不同的出行需求,直接影响共享出行系统的服务效率和乘客体验。常用的车辆调度方法是基于位置的贪心算法,即指派最近或旅行时间最短的司机为乘客服务^[40-41]。贪心算法易于实现,但只注重乘客的即时满意度,无法保证全局供应利用率,而且由于车辆供应和乘客需求不匹配,只能得到次优结果。此后有学者基于多智能体系统理论给出一种车辆调度方法^[42],可实现等待时间或接送距离的全局最小化,但计算时间长,成功率低。

上述结果针对单人乘车的情况,未考虑车辆共乘。实际中,具有相近行程的乘客可共享同一辆车并分摊成本,提高系统吞吐量和车辆利用率,从而减小系统中的车辆数量,节省成本。常见的共乘车辆调度机制有两种,一是平行竞价机制^[43],另一种是定价机制^[44]。其中竞价机制要求乘客公开提出共乘报价,由于涉及乘客的隐私,不太实用;定价机制只需乘客接受运营商的报价,无需公开竞价,所以更有吸引力。不

过,已有研究只考虑共乘乘客的价格动机,忽略了旅行时间、舒适性和隐私等决定人们选择共乘服务的重要因素。另外,已有研究基于共乘请求的离线批处理,而不是实时在线处理。要提高按需出行系统的服务质量和吸引力,无论从运营商角度还是出行者角度,都希望能够对乘客通过智能终端发出的每个请求做出即时的响应。为此,文献[45]针对需求固定的应用场合给出一种可即时响应客户请求的调度方法。关于实时共乘车辆调度的研究较少^[46-47],且未考虑交通事故和道路拥堵等实时路况,其结果可能使当前出行需求的最佳时间表发生延迟,从而不满足用户对上下车时间的要求。因此,当前急需考虑出行需求的动态性、出行时间要求等非经济因素以及交通环境的随机性的实时车辆调度方法。

2.1.2 系统车辆再平衡

系统车辆再平衡是共享出行系统的核心问题,是系统稳定运行的前提。已有方法分为基于运营商的车辆再平衡^[48-49]和基于用户的车辆再平衡^[50-51]两种。

基于运营商的车辆调度策略旨在从运营商角度出发,最大限度地降低系统运行成本,同时最大化服务收益,保证系统服务的便利性。这种策略由系统操作人员或运营管理软件执行,重点关注系统特定性能和参数的优化。文献[52]给出一种优化-趋势-仿真三阶段决策支持系统,寻求可使车辆共享系统人力资源成本最小的最优系统参数值。文献[53]提出一种能使车辆共享系统收益和运行成本最优的混合整数优化方法,以此确定车队规模、车辆数、车站规模和潜在停车点位置。在保证运营商成本和利润的同时,必须同时保证系统的服务质量(如乘客等待时间、旅行时间)和用户满意度。为此,文献[54]提出一种基于离散事件动态系统的车辆再平衡调度方法,即使出行需求增长后也可用最小车队规模最大限度地保证用户满意度即服务质量。上述研究考虑不同时间的出行需求,得到的是静态模型,并没有考虑出行需求的动态变化带来的影响,特别是乘车需求变化具有显著的随机性,是系统保证服务质量必须考虑的重要因素之一^[55]。因此,文献[56]研究了出行需求变化对车辆再平衡调度的影响,提出一种车辆再平衡调度最小成本流算法。但是,该方法是在最大允许车队规模下给出的,没有权衡系统特性(如车队规模)参数对车辆再平衡调度的影响。

基于用户的车辆再平衡通过影响用户的出行行

为实现系统车辆再平衡,主要目的是在损失可接受及便利性条件下提升经济效益,减少资源浪费.文献[57]提出两种基于用户的再平衡方案:当某一站点有多余车辆时,将该站点的用户分配到不同车辆,从而将车辆调度到车辆较少的站点;当出发地车辆过少而目的地车辆冗余时,多个用户被分配到同一车辆以缓解车辆不平衡.为了兼顾成本和平衡,文献[58]提出基于奖励机制的调度策略,以折扣或奖励的形式引导用户将车停在运营商建议的站点.已有的基于用户的车辆再平衡调度方法常假设单位时间内的未来需求已知,而实际出行需求随时变化,因此这些方法并不能完全解决不平衡现象.能利用车辆和用户的轨迹数据、出行需求信息和实时交通状态等因素,对用户的未来需求进行预测,然后基于需求预测实现车辆的优化调度,将是非常有意义的.

2.2 考虑电车充电的再平衡

共享出行系统中通常大量使用电动汽车,而电动汽车续航能力有限、充电时间相对较长,为保证出行的时效性,车辆调度和系统再平衡的同时必须考虑电车充电问题.针对电量约束问题,研究人员通过对经典的“最短路径”问题进行拓展^[59-61],给出了单个电车的最优路径规划方法,但不适用于共享出行系统的整体车队调度.最近,文献[62-64]从车队层面出发,给出了一种基于排队论的电车充电路由方法,通过优化到不同电站充电的车辆比例,实现充电调度.不过,这些结果没考虑车辆电量状态,也未考虑系统的再平衡问题.

基于电动汽车共享出行系统的再平衡问题极具挑战性,充电调度既要考虑实时电价和电量约束,又要保证系统持续稳定运行的低成本和高收益.文献[65]首次同时考虑再平衡与电池容量约束问题,提出基于状态空间模型和模型预测控制(MPC)算法的共享车辆再平衡调度方法.值得指出的是,受充电速度、电网功率及供电间歇特性等因素限制,充电规划的时间尺度(约几小时)远大于运输规划的时间尺度(约15~40 min),此前的研究并未考虑这一因素.文献[66]在文献[65]的基础上考虑时间尺度差异,提出一种解决再平衡充电调度问题的两层优化方法.虽然基于MPC的再平衡充电调度方法^[65-66]效果良好,但这种全局优化方法只适用于小规模系统.与小规模系统侧重于电量约束不同,大规模共享出行系统的充电规划与再平衡问题更受限于电网电价^[67]、电网功率^[68]等宏观因素,适宜采用启发式方法解决^[69].

2.3 电车交通网-电网复合优化

交通电气化正推动着交通网与电网的耦合.电动汽车一方面作为一种可变负载,充电行为复杂,大量的充电需求及高度随机的充电时间将严重影响电力系统的稳定^[70-71];另一方面,作为一种存储设备,电动汽车向电网输送电能(V2G)反而可以跨时空实现电网的互补消纳,如图1所示.

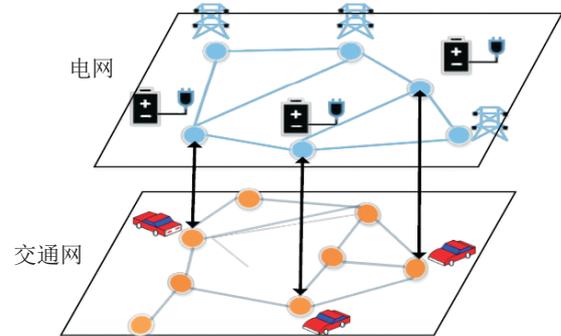


图1 电车交通网络与电力网络耦合

为了提高电网侧稳定性,减轻高峰时段微电网的额外负荷,文献[72]提出一种智能分布式动态充电(D2P)机制引导供需平衡.文献[73]提出一种充电站网络随机模型,以最优方式从电网向充电站分配电力.然而,上述方案忽略了电能可能来自间歇性可再生能源(如风能或太阳能).因此,文献[74]提出了一种集成能源管理系统,将不可控的可再生能源纳入电网,文献[75]进一步通过新型的分布式模型预测控制方法来促进微电网子系统间的相互协调.

交通网侧可以通过规划最优充电时间^[76]、保证负载平衡^[77]等手段消除交通网对电网的不利影响,也可以结合V2G技术使电动汽车参与智能电网的调峰、调压、调频等^[78-80]优化过程.文献[78]考虑电池特性,通过对单个电动汽车的放电控制实现对电网的频率调节,但忽略了电池荷电状态.文献[79]进一步考虑车辆后续服务所需的电量下限,提出了电动汽车参与微电网频率调节的两层控制系统.实际上,V2G的具体实现往往包含在车辆的最优调度当中,越来越多的研究也正围绕交通网-电网的耦合特性展开,单一交通侧的优化问题正在向交通网、电网联合优化的方向转变,已经衍生出基于车队的充电网络性能分析^[81]、车-电联合调度^[68]和联合调度下的充电站规划^[82]等新方向.

3 基于网联车辆的车路协同优化与控制

基于网联车辆和车路协同控制的智能车路系统是智能交通技术的未来发展目标^[83-84].网联车辆具有很强的信息交互和协作行驶能力,可通过信息

交换和协作行驶提高交通安全性、机动性和道路容量,减少能量消耗.这些优越性已被美国PATH^[85]、欧洲SARTRE^[86]和日本Energy-ITS^[87]等研究计划验证.智能车路系统中,人、车、路互相交互,构成信息过程和物理行驶过程高度融合,计算、通信与控制紧密关联的交通信息物理系统.这种车队协作行驶模式彻底改变了交通运输系统的运行方式,由反应式、局部自组织、小数据简明信息下的交通控制,向预期/反应混合式、全局规划、大数据海量信息下的交通控制发展^[88-89],系统中亟待解决的核心难题包括车辆协调编组与合并^[90]、车队速度优化与控制等^[91-92].

3.1 车辆协调编组合并决策

车辆协调编组与合并可分为主动式和被动式两种,主动式指车辆在行驶中有机会时会主动与邻近车辆协调编组列队行驶.被动式协调编组合并是车辆按照交通管理者预先根据车辆行驶路线和任务所作的决策,在指定地点、指定时间与指定车辆编组列队行驶.这种编组决策过程包括确定编队车辆、合并时间地点、路径以及车辆在车队中的位置顺序等,根据车辆路径是否固定,一般采取长期规划、短期调整的决策方式.对于路径固定的车辆,一般在执行任务前进行长期规划,通过调整车辆出发时间和/或速度,使运输车队的车辆共同路径最长,以提高合并编队率.另外,由于实际中随时有车辆加入或离开编组,考虑到实时交通流等影响因素,车辆的整体规划需要实时调整,或局部调整车辆行驶路径.当车辆路径不固定时,还可对路网中的车辆进行分类规划运输任务,根据油耗、成本等指标确定不同车辆的出发时间,以获得更为合理的车队分组.通常需要首先确定每辆车的最短路径,然后根据时间和速度约束确定可行编组策略,从中获得最优解.不过,当运输车队中的车辆数较多时,该方法并不适用.

车辆的出行时间对于车辆协调编组与合并至关重要.由于实时交通状况和道路状况实时变化,车辆经过特定路段的行驶时间并不确定,合理的出发时间是保证时效性和成本的关键因素.文献[93]对此问题进行了研究,考虑行驶时间的不确定性,根据准时性指标和油耗成本,给出了车队发车时间优化调度方法.车辆协调变组与合并决策过程计算量较大,尤其当车辆数量较大时,必须寻求计算高效的优化决策方法.文献[94]基于油耗最小化原则,根据运输任务(即车辆的起点、目的地、出发时间和到达时间)给出了大规模车辆编组合并的最优路径和速度曲线;文献[95]将大规模车辆编组合并决策问题转化为聚类问题,并

采用中心点聚类算法求解.

车辆的编组合并决策还常常受服务时间窗等条件的约束,此时问题的求解更为复杂,但也已取得可喜进展.文献[96]针对有时间窗限制的多辆车协调编组合并问题给出了一种有效的解决办法;文献[97]考虑不同物理特性(如负载)车辆的分类协调编组合并问题,给出了一种启发式方法;文献[98]针对共乘应用场景,给出了一种车辆编组合并决策方法.

3.2 车队速度优化与控制

车辆近距离列队行驶可降低空气阻力和油耗,提高道路容量,是最早实用化的智能交通技术之一,称为道路火车技术.车辆编队控制系统通常采用两层控制结构,上层负责速度的优化设定,下层负责车队速度的协同跟踪控制,保证车队稳定和交通流稳定,下面分别论述.

1) 车队速度优化.

已有的车队协作控制研究通常针对平坦道路,因此假设车辆以给定的恒定速度行驶^[99].对于重量和大小不同的车辆,不同的速度导致不同的能源消耗.由于实际道路坡度和限速多变,采用恒定的参考速度显然不尽合理.现有研究大多只研究单个车辆的速度优化问题,根据车辆动力学特性、速度与效率表以及油耗特性,给出车辆的节能高效行驶速度.由于车辆异构性和前后车的耦合,车队整体的速度优化极具挑战性,相关研究刚刚起步.文献[100-101]考虑路面坡度信息和速度限制因素,给出基于纵向驱动力最大化或燃油消耗最小化的领队车最优速度曲线,减少了不必要的加速和制动次数.

上述研究通过领队车速度优化实现车队速度最优设定,这种速度优化方法没有考虑车队中的车辆大小和重量差异,不能保证异构车队的整体能耗最小.为此,文献[102]根据油耗与时间指标,提出一种基于庞特里亚金最小原理的车辆最优速度优化设定方法,并以各车辆最优速度的平均值作为车队的参考速度.平均速度优化方法比较符合实际需要,文献[103]给出了另一种平均优化方法,将车队作为整体建立其平均模型,然后利用动态规划算法获得车队最优参考速度的设定值.

除了在车队速度的优化设定中考虑不同车辆大小和重量因素,还应考虑道路坡度和限速的变化.文献[104]给出车队速度优化设定的变步长动态规划方法,由于道路坡度和限速实际上是在不同空间位置上发生变化,而不是在特定时间上变化,进而给出了基于空间采样进行车队速度优化设定的动态规划方法,

以及相应的变空间步长动态规划车队速度优化设定方法。

2) 车辆协作控制.

车辆协作控制系统的设计需要考虑车队间距策略、车辆通信拓扑以及车队控制器设计3方面的问题. 车队控制的目标是所有车辆以期望的车间距和相同的速度行驶,常用的间距策略有两种,根据车间距是否依赖车速分为固定车间距和可变车间距^[105]. 固定车间距策略可提高道路利用率,但队列稳定性对车辆间的通信要求较高. 可变间距策略更符合驾驶行为习惯,容易保证车队稳定,但车速较高时,车间距太大,达不到降低油耗和提高道路容量的目的. 常用的可变车距策略将期望车间距设定为速度的线性函数,当线性函数的系数为常数时,车间距对应着固定的行驶时间,称作固定时距策略. 线性函数也可以是时变或非线性的^[106-108],文献[109]给出了一种通用的时变间距策略,通过设计不同的间距函数的参数保证车辆队列稳定和交通流稳定. 当然,车间距策略也可以考虑其他因素,如文献[110]提出的基于延迟定义的车间距策略. 间距策略与道路容量息息相关,对交通流的稳定会产生重要影响,因此,车间距设计要兼顾协作控制性能、交通流稳定性和交通容量的平衡.

车队的通信拓扑是指车辆控制所用的反馈信息流,对车队的稳定性有重要影响. 常用的信息流拓扑有前车跟随结构、领队车-跟随结构、双向通信结构和领队车-双向通信结构等,也可以采用其他信息流拓扑结构,如双前车-跟随、双前车-领头车跟随等,具体采用何种需要根据协作控制性能和车队稳定性确定. 引入无线通信可改善车队控制性能,但无线通信带宽有限也导致延时和丢包等问题^[111]. 为了避免通信问题的影响,可采用基于事件的通信触发机制减少不必要的通信^[112]. 文献[113-114]研究了网络延时对车队稳定性的影响,给出队列稳定性的延时条件. 文献[115]给出了保证车辆队列稳定所需的数据丢包率.

车队控制系统分为集中式控制和分布式控制两种,其中集中式控制方法直接将车队作为一个结构化的系统,通常基于车队稳定性和串稳定性分析来设计集中式控制器^[116-118]. 集中式控制方法便于设计,但其计算效率随车队规模增加大大降低. 分布式控制是将车队分解成单个车辆子系统单独设计各自的控制器,这种方法更为实用. 常用于分布式车队控制的方法有自适应控制^[119]、滑模控制^[99]、滚动时域最优

控制或模型预测控制等^[120]. 由于车辆队列行驶控制本质上是多智能体系统,采用多智能体分布式控制方法设计也十分方便,文献[121]即利用多智能体一致性控制思想提出一种车队控制方法.

3.3 车路协同控制

车路协同控制是智能交通系统的重要方向,很多国家推出了车路协同研究计划,如美国的IntelliDrive、欧盟的COOPERS、日本的SmartWay、我国863计划中的I-VICS等^[122]. 车路协同系统利用车-车、车-路、车-人间的信息通信共享,实现车辆与交通设施的智能协同控制与优化. 车路协同系统不局限于交通信号灯控制,可基于信号灯实现车速引导控制,也可基于车辆位置和速度等状态实现路口信号灯优化控制,还可实现多个交叉路口的信号灯协同控制,使交通控制发生根本性变化,从基于信号灯的被动控制向车路协同的主动控制方向发展. 目前,车路协同控制研究主要集中在如下几方面:车辆路权优先控制、基于车辆速度的交通信号灯控制、基于信号灯的车辆速度优化、虚拟交通信号控制、交通信号与车辆速度协同优化.

1) 车辆路权优先控制.

传统的特殊车辆(救护车/公交车/有轨电车等)路权优先控制方法是提供专用车道^[123],而车路协同系统中可通过信号优先权控制实现^[124-127]. 其基本思想是,基于历史车流信息、车辆实时位置及交通信号灯实时状态,设计车辆信号优先权,以减少特殊车辆与普通车辆的冲突,也可对特殊车辆信号优先策略和路径进行协同设计. 最常见的是公交车辆信号特权策略研究,如文献[128]研究了有轨电车整个线路中的行驶速度与多路口交通信号灯协同设计问题,给出有轨电车运行时刻表与多路口信号特权策略;文献[129]通过对公交车行驶速度与站点驻留时间的协同优化,提高了信号优先策略的效率;文献[130]基于公交车站点驻留时间概率分布模型和路口社会车辆排队模型,设计了信号优先策略;文献[131]研究了连续多路口的公交车自适应信号优先策略.

2) 基于车辆速度的交通信号灯控制.

对于单路口信号灯的控制问题,一般通过线圈、GPS等信息估计不同车辆/车队到达路口的时间^[132-133]和排队长度,进行交通信号灯配时优化. 随着大部分车辆配备GPS设备,可根据所有车辆的实时数据预测车辆速度和位置状态以及行驶轨迹,采用整数规划等方法对交通信号灯配时进行精细优化和控制^[134],减少通行延误与燃油消耗^[135]. 上述研究针

对的是单一路口,对于路网中的多路口信号灯协同控制,可结合多个路口的不同通过率设计车流通行绿波带,并根据预测的车辆轨迹将车流划分为不同的分段状态来优化不同路口的信号灯配时^[136].

3) 基于信号灯的车辆速度优化.

这方面研究多基于信号灯相位时间信息和车辆/车队燃油经济性进行速度轨迹优化,通过减少车辆在路口的停车时长、减少速度变化和发动机空转提高燃油经济性^[137].也有文献研究了车辆换挡的影响和路口车队分裂/合并时的速度规划问题,如文献[138]考虑车辆离散档位变化提出了路口速度规划与非线性最优控制方法.以上研究均没有考虑车辆间的相互影响,如目标车辆/车队前方的自由行驶车辆对目标车辆会有严重影响.为此,文献[139]考虑目标车辆周围车辆的状态以及交通信号信息,提出了一种最优速度轨迹规划方法;文献[140]基于路口车辆排队长度估计信息,给出了一种速度轨迹规划方法;文献[141]基于路口排队长度实时变化给出了车辆最优减速/加速轨迹计算方法.

4) 虚拟交通信号控制.

当道路中车辆全部搭载有智能车载设备或全部为自动驾驶车辆时,可通过车路协同系统直接向车辆发送通行信息,无需物理的交通信号灯,这是交通系统未来的发展方向.早期的成果^[142-143]按照领导车选择、信号构建与传播、领导车移交等步骤设置通行权限并分发至车辆,但并未研究车辆行驶轨迹优化问题.最近,人们开始研究车辆轨迹与通行权协同分配问题^[144-148],基于车辆间时距协同设计车辆的通行轨迹,避免车辆通行时发生轨迹重叠.也有文献基于车队概念,规划各虚拟车队的通行轨迹,避免冲突,提高燃油经济性.无信号灯路口的通行控制也受到很多人的关注,文献[147]研究了无信号灯路口的多车辆轨迹规划问题.上述研究对所有接近路口的车辆进行轨迹规划,导致问题维度较高,难以求解,最近一些研究成果将规划问题分层或分解进行简化,如文献[148]将规划问题分为两层,上层通过混合整数线性规划实现通行时间最小化,下层用线性规划使车辆平均速度最大化.

5) 交通信号与车辆速度协同优化.

对于近饱和混合交通路口等复杂交通环境,有必要进行交通信号与车辆速度的协同优化控制^[149].不过,交通信号控制与车辆速度轨迹协同设计问题维度高,求解难,可采用分层设计和启发式方法^[150]降低求解复杂度.如文献[151-152]给出一种双层结构,其

中上层集中式优化交通信号以及车辆到达路口的时间,下层采用分布式方法实现车辆节油最优速度控制.当车流中有部分车辆未搭载智能车载设备或为了缩小问题规模时,可将道路中的车辆分成不同车队,并将搭载智能车载设备、可进行速度规划的车辆作为各车队的领头车,以车队为单位进行速度协同规划,对各车队领头车到达路口的时间和交通信号进行协同规划,然后规划各车队领头车的速度轨迹^[153-154].单一路口的交通信号与车辆速度的协同规划问题相对简单,已有方法相对成熟.当前的研究焦点在于局部或整体路网的交通信号与车辆速度轨迹规划,这一问题非常困难,还处在起步阶段,需针对整体车流而非单个车辆进行设计^[155],对各路口的交通信号偏移量和各路段的车流平均速度进行优化,以降低整体燃油消耗与通行时间.

4 问题与展望

网联车辆、汽车共享、大数据等技术正在将智能交通系统引向网联共享、车路协同、数据赋能、按需出行的变革性发展方向,被认为是人类社会发展的一个难得机遇.同时,智能交通系统也面临诸多理论和技术挑战.

1) 交通系统的建模和预测十分困难,已有的交通预测方法多以静态或移动观测数据为基础,采用不同的深度学习模型预测交通流量、交通流速度和出行需求分布.基于历史数据建立的模型只能描述稳态及低随机度交通环境,而实际问题具有高随机性.而且,这类方法过分依赖数据和智能方法,而忽视对相关本身机理的认识和研究.未来应探讨综合运用数据、智能方法和机理知识的交通预测预报技术.另外,外部因素(如天气和特殊事件等)也会影响交通出行活动^[156],因此,用非交通数据丰富输入数据的特征维度,探讨更精确、高效的交通预测方法也值得深入研究.

2) 传统交通系统运行优化研究假设出行需求的时空分布确定,而实际出行需求的时间、空间分布是高度动态、不确定的,因此,现有的车辆调度方法无法保证系统动态再平衡和乘客等待时间等服务质量指标,难以适应高效、可持续的按需出行要求,急需研究实时动态匹配需求和车辆的任务分配和路线规划方法^[157].尤其是共享出行系统与传统公共出行方式(如出租车、公交、地铁等)共同形成的多模式混合交通系统,其运行优化非常具有挑战性,是未来的重要研究课题.

3) 电动汽车等新能源汽车大量进入交通网络

后,交通网络与电网的耦合问题将会更加突出. 交通网-电网耦合系统的整体性能取决于电网负荷状态、可用于V2G的电车数量、充电站规模、交通网络状态等因素,因此,交通系统运行调度、电车充电管理与电网负荷功率分配、调峰定价优化等问题将相互交叠,且其相互影响的不确定性较大. 可见,交通网-电网耦合系统的集成优化是亟待解决的重要难题.

4) 基于车联网的车辆通信调度和车辆协作控制是下一代智能交通系统亟待解决的核心技术难题之一,面临大规模车辆协作控制和通信两方面的挑战. 一方面,近距离行驶的车辆关联耦合,受车载传感器和车联网技术性能所限,在拥挤道路上的高速协作行驶控制非常困难. 另一方面,车联网通信带宽有限,网络状态和通信服务质量受环境和周围车辆影响,且现有车联网协议未考虑大量车辆实时协作控制时的频繁、时间紧要通信需求,无法解决大量车辆协作行驶控制时的通信冲突问题,因此不能保证车辆协作控制所需信息和数据的时效性和可靠性^[158-159]. 即使5G技术进入实用化,这一问题也不会自动解决,所以,困扰车联网和智能交通系统的这一瓶颈问题迫切需要破解.

5) 交通系统的车路协同优化控制问题极具挑战,需要分层求解,即分解成基于道路信息和信号灯状态的车辆协作控制、基于车流信息的信号灯优化配时控制、基于车路协同的区域路网交通优化等子问题分别解决. 但是,这种分而治之的方法其数学计算非常复杂,现有结果只能得到次优解,很难保证满意的性能. 对于大范围交通信号和车辆速度规划,如干线或区域路网的车路协同控制问题,即使分层处理也会遭遇“维数灾难”而无法求解,急需高效的精细化求解方法. 另外,为降低对精确建模的依赖,探索利用深度学习等方法提高车路协同控制的适应性与鲁棒性,也是未来值得研究的重要方向.

6) 人们的出行规律对交通规划、交通预测乃至疾病传播研究具有重要意义,基于移动电话、车载GPS和智能卡记录的出行大数据为研究人们的出行时空轨迹提供了有力的工具. 研究表明,尽管交通工具、工作家庭地点等很多因素都会影响人们的出行模式,但每个人的出行活动时空轨迹具有高度规律性,表现为一个不依赖于时间的特征旅行距离,并以显著概率返回到少数几个常驻地. 简言之,虽然个体出行历史记录多样化,但出行规律基本都满足某种空间概率分布,遵循一种简单可重复的模式^[160]. 所以,研究基于人们出行规律的交通规划、车辆部署与调

度、交通系统建模与预测等方法和技术,也是未来的重要研究方向.

参考文献(References)

- [1] Van Mierlo J, Maggetto G. Fuel cell or battery: Electric cars are the future[J]. *Fuel Cells*, 2007, 7(2): 165-173.
- [2] Golob T F, Recker W W. Relationships among urban freeway accidents, traffic flow, weather, and lighting conditions[J]. *Journal of Transportation Engineering*, 2003, 129(4): 342-353.
- [3] Bedard M, Guyatt G H, Stones M J, et al. The independent contribution of driver, crash, and vehicle characteristics to driver fatalities[J]. *Accident Analysis & Prevention*, 2002, 34(6): 717-727.
- [4] Chen Q, Song X, Yamada H, et al. Learning deep representation from big and heterogeneous data for traffic accident inference[C]. *The AAAI Conference on Artificial Intelligence*. Phoenix: AAAI Press, 2016: 338-344.
- [5] Ren H, Song Y, Wang J, et al. A deep learning approach to the citywide traffic accident risk prediction[C]. *The 21st International Conference on Intelligent Transportation Systems (ITSC)*. Hawaii: IEEE, 2018: 3346-3351.
- [6] Bandeira J M, Fontes T, Pereira S R, et al. Assessing the importance of vehicle type for the implementation of eco-routing systems[J]. *Transportation Research Procedia*, 2014, 3: 800-809.
- [7] Rakha H, Ahn K, Trani A. Development of VT-Micro model for estimating hot stabilized light duty vehicle and truck emissions[J]. *Transportation Research, Part D: Transport and Environment*, 2004, 9(1): 49-74.
- [8] Beckx C, Panis L I, Janssens D, et al. Applying activity-travel data for the assessment of vehicle exhaust emissions: Application of a GPS-enhanced data collection tool[J]. *Transportation Research, Part D: Transport & Environment*, 2010, 15(2): 117-122.
- [9] Wang H, Chen C, Huang C, et al. On-road vehicle emission inventory and its uncertainty analysis for Shanghai, China[J]. *Science of the Total Environment*, 2008, 398(1/2/3): 60-67.
- [10] Cai H, Jia X, Chiu A S F, et al. Siting public electric vehicle charging stations in Beijing using big-data informed travel patterns of the taxi fleet[J]. *Transportation Research, Part D: Transport and Environment*, 2014, 33: 39-46.
- [11] Luo X, Dong L, Dou Y, et al. Analysis on spatial-temporal features of taxis' emissions from big data informed travel patterns: A case of Shanghai, China[J]. *Journal of Cleaner Production*, 2017, 142(2): 926-935.
- [12] Yee P, Haykin S. A dynamic regularized gaussian radial basis function network for nonlinear, nonstationary time series prediction[J]. *IEEE Transactions on Signal Processing*, 1995, 47(9): 2503-2521.

- [13] Okutani I, Stephanedes Y J. Dynamic prediction of traffic volume through Kalman filtering theory[J]. *Transportation Research, Part B: Methodological*, 1984, 18(1): 1-11.
- [14] Chang H, Lee Y, Yoon B, et al. Dynamic near-term traffic flow prediction: system-oriented approach based on past experiences[J]. *IET Intelligent Transport Systems*, 2012, 6(3): 292-305.
- [15] Lippi M, Bertini M, Frasconi P. Short-term traffic flow forecasting: An experimental comparison of time-series analysis and supervised learning[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2013, 14(2): 871-882.
- [16] Chan K Y, Dillon T S, Singh J, et al. Neural-network-based models for short-term traffic flow forecasting using a hybrid exponential smoothing and Levenberg-Marquardt algorithm[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2012, 13(2): 644-654.
- [17] Cetin M, Comert G. Short-term traffic flow prediction with regime switching models[J]. *Transportation Research Record*, 2006, 1965(1): 23-31.
- [18] Chang S C, Kim R S, Kim S J, et al. Traffic-flow forecasting using a 3-stage model[C]. *Proceedings of the IEEE Intelligent Vehicles Symposium*. Dearborn: IEEE, 2002: 451-456.
- [19] Tan M C, Wong S C, Xu J M, et al. An aggregation approach to short-term traffic flow prediction[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2009, 10(1): 60-69.
- [20] Lv Y, Duan Y, Kang W, et al. Traffic flow prediction with big data: A deep learning approach[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2015, 16(2): 865-873.
- [21] Zeng X, Zhang Y. Development of recurrent neural network considering temporalspatial input dynamics for freeway travel time modeling[J]. *ComputerAided Civil and Infrastructure Engineering*, 2013, 28(5): 359-371.
- [22] Yu H, Wu Z, Wang S, et al. Spatiotemporal recurrent convolutional networks for traffic prediction in transportation networks[J]. *Sensors*, 2017, 17(7): 1501-1510.
- [23] Ma X, Zhang J, Du B, et al. Parallel architecture of convolutional bi-directional LSTM neural networks for network-wide metro ridership prediction[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2018, 99: 1-11.
- [24] Yu B, Yin H, Zhu Z. Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting[C]. *Proceedings of the 27th International Joint Conference on Artificial Intelligence (IJCAI)*. Stockholm: AAAI Press, 2018: 3634-3640.
- [25] Zhao K, Khryashchev D, Freire J, et al. Predicting taxi demand at high spatial resolution: Approaching the limit of predictability[C]. *International Conference on Big Data*. Washington, DC: IEEE, 2016: 833-842.
- [26] Rong H, Zhou X, Yang C, et al. The rich and the poor: A Markov decision process approach to optimizing taxi driver revenue efficiency[C]. *Proceedings of the 25th ACM International on Conference on Information and Knowledge Management*. Indianapolis: ACM, 2016: 2329-2334.
- [27] Li X, Pan G, Wu Z, et al. Prediction of urban human mobility using large-scale taxi traces and its applications[J]. *Frontiers of Computer Science*, 2012, 6(1): 111-121.
- [28] Davis N, Raina G, Jagannathan K. A multi-level clustering approach for forecasting taxi travel demand[C]. *The 19th International Conference on Intelligent Transportation Systems (ITSC)*. Rio de Janeiro: IEEE, 2016: 223-228.
- [29] Vlahogianni E I, Karlaftis M G, Golias J C. Short-term traffic forecasting: Where we are and where we're going[J]. *Transportation Research, Part C: Emerging Technologies*, 2014, 43: 3-19.
- [30] Chen C, Zhang D, Li N, et al. B-planner: planning bidirectional night bus routes using large-scale taxi GPS traces[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2014, 15(4): 1451-1465.
- [31] Xu J, Rahmatizadeh R, Bölöni L, et al. Real-time prediction of taxi demand using recurrent neural networks[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2017, 19(8): 2572-2581.
- [32] Ke J, Zheng H, Yang H, et al. Short-term forecasting of passenger demand under on-demand ride services: A spatio-temporal deep learning approach[J]. *Transportation Research, Part C: Emerging Technologies*, 2017, 85: 591-608.
- [33] Baek J, Sohn K. Deep-learning architectures to forecast bus ridership at the stop and stop-to-stop levels for dense and crowded bus networks[J]. *Applied Artificial Intelligence*, 2016, 30(9): 861-885.
- [34] Wang D, Yang Y, Ning S. Deepstcl: A deep spatio-temporal convlstm for travel demand prediction[C]. *International Joint Conference on Neural Networks (IJCNN)*. Rio de Janeiro: IEEE, 2018: 1-8.
- [35] Tian Y, Chiu Y C. A variable time-discretization strategies-based, time-dependent shortest path algorithm for dynamic traffic assignment[J]. *Journal of Intelligent Transportation Systems*, 2014, 18(4): 339-351.
- [36] Pavone M, Smith S L, Frazzoli E, et al. Robotic load balancing for mobility-on-demand systems[J]. *International Journal of Robotics Research*, 2012, 31(7): 839-854.
- [37] Zhang R, Pavone M. Control of robotic

- mobility-on-demand systems[J]. *International Journal of Robotics Research*, 2014, 35(1/2//3): 186-203.
- [38] Goodwin G C, Medioli A M. Scenario-based, closed-loop model predictive control with application to emergency vehicle scheduling[J]. *International Journal of Control*, 2013, 86(8): 1338-1348.
- [39] Tang W, Zhang Y J A. A model predictive control approach for low-complexity electric vehicle charging scheduling: Optimality and scalability[J]. *IEEE Transactions on Power Systems*, 2016, 32(2): 1050-1063.
- [40] Liao Z. Real-time taxi dispatching using global positioning systems[J]. *Communications of the ACM*, 2003, 46(5): 81-83.
- [41] Lee D H, Wang H, Cheu R L, et al. Taxi dispatch system based on current demands and real-time traffic conditions[J]. *Transportation Research Record*, 2004, 1882(1): 193-200.
- [42] Seow K T, Dang N H, Lee D H. A collaborative multiagent taxi-dispatch system[J]. *IEEE Transactions on Automation Science and Engineering*, 2009, 7(3): 607-616.
- [43] Kleiner A, Nebel B, Ziparo V A. A mechanism for dynamic ride sharing based on parallel auctions[C]. *The 42nd International Joint Conference on Artificial Intelligence*. Barcelona: AAAI Press, 2011: 266-272.
- [44] Cheng S F, Nguyen D T, Lau H C. Mechanisms for arranging ride sharing and fare splitting for last-mile travel demands[C]. *Proceedings of the 2014 International Conference on Autonomous Agents and Multi-agent Systems*. Paris: ACM, 2014: 1505-1506.
- [45] Zhao D, Zhang D, Gerding E H, et al. Incentives in ridesharing with deficit control[C]. *International Conference on Autonomous Agents & Multi-agent Systems*. Paris: ACM, 2014: 1021-1028.
- [46] Huang Y, Bastani F, Jin R, et al. Large scale real-time ridesharing with service guarantee on road networks[J]. *Proceedings of the VLDB Endowment*, 2014, 7(14): 2017-2028.
- [47] Ma S, Zheng Y, Wolfson O. Real-time city-scale taxi ridesharing[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2014, 27(7): 1782-1795.
- [48] Boyac B, Zografos K G, Geroliminis N. An optimization framework for the development of efficient one-way car-sharing systems[J]. *European Journal of Operational Research*, 2015, 240(3): 718-733.
- [49] Bruglieri M, Colorni A, Luè A. The relocation problem for the oneway electric vehicle sharing[J]. *Networks*, 2014, 64(4): 292-305.
- [50] Di Febbraro A, Sacco N, Saeednia M. One-way carsharing: Solving the relocation problem[J]. *Transportation Research Record*, 2012, 2319(1): 113-120.
- [51] Uesugi K, Mukai N, Watanabe T. Optimization of vehicle assignment for car sharing system[C]. *International Conference on Knowledge-Based and Intelligent Information and Engineering Systems*. Berlin: Springer, 2007: 1105-1111.
- [52] Kek A G H, Cheu R L, Meng Q, et al. A decision support system for vehicle relocation operations in carsharing systems[J]. *Transportation Research, Part E: Logistics and Transportation Review*, 2009, 45(1): 149-158.
- [53] Correia G H D A, António Pais Antunes. Optimization approach to depot location and trip selection in one-way carsharing systems[J]. *Transportation Research, Part E: Logistics & Transportation Review*, 2012, 48(1): 233-247.
- [54] Fassi A E, Awasthi A, Viviani M. Evaluation of carsharing network's growth strategies through discrete event simulation[J]. *Expert Systems with Applications*, 2012, 39(8): 6692-6705.
- [55] Fan W, Machemehl R B, Lownes N E. Carsharing: Dynamic decision-making problem for vehicle allocation[J]. *Transportation Research Record*, 2008, 2063(1): 97-104.
- [56] Jorge D, Correia G, Barnhart C. Testing the validity of the MIP approach for locating carsharing stations in one-way systems[J]. *Procedia-Social and Behavioral Sciences*, 2012, 54: 138-148.
- [57] Barth M, Todd M, Xue L. User-based vehicle relocation techniques for multiple-station shared-use vehicle systems[J]. *Transportation Research Record*, 2004: 137-144.
- [58] Angela D F, Nicola S, Mahnam S. One-way car-sharing profit maximization by means of user-based vehicle relocation[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2018: 1-14.
- [59] Yang H, Yang S, Xu Y, et al. Electric vehicle route optimization considering time-of-use electricity price by learnable partheno-genetic algorithm[J]. *IEEE Transactions on Smart Grid*, 2015, 6(2): 657-666.
- [60] Li C, Ding T, Liu X, et al. An electric vehicle routing optimization model with hybrid plug-in and wireless charging systems[J]. *IEEE Access*, 2018, 6: 27569-27578.
- [61] Shao S, Guan W, Bi J. Electric vehicle-routing problem with charging demands and energy consumption[J]. *IET Intelligent Transport Systems*, 2018, 12(3): 202-212.
- [62] Ammous M, Belakaria S, Sorour S, et al. Optimal cloud-based routing with in-route charging of mobility-on-demand electric vehicles[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2018, 20(7): 2510-2522.
- [63] Belakaria S, Ammous M, Sorour S, et al. A multi-class dispatching and charging scheme for autonomous electric mobility on-demand[C]. *The 86th Vehicular Technology Conference (VTC-Fall)*. Toronto: IEEE, 2017: 1-5.

- [64] Belakaria S, Ammous M, Smith L, et al. Multi-class management with sub-class service for autonomous electric mobility on-demand systems[J]. *IEEE Transactions on Vehicular Technology*, 2019, 68(7): 7155-7159.
- [65] Zhang R, Rossi F, Pavone M. Model predictive control of autonomous mobility-on-demand systems[C]. *International Conference on Robotics and Automation (ICRA)*. Stockholm: IEEE, 2016: 1382-1389.
- [66] Iacobucci R, McLellan B, Tezuka T. Optimization of shared autonomous electric vehicles operations with charge scheduling and vehicle-to-grid[J]. *Transportation Research, Part C: Emerging Technologies*, 2019, 100: 34-52.
- [67] Zhu M, Liu X Y, Wang X D. Joint transportation and charging scheduling in public vehicle systems—A game theoretic approach[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2018, 19(8): 2407-2419.
- [68] Rossi F, Iglesias R D, Alizadeh M, et al. On the interaction between Autonomous Mobility-on-Demand systems and the power network: Models and coordination algorithms[J]. *IEEE Transactions on Control of Network Systems*, 2019, DOI: 10.1109/TCNS.2019.2923384.
- [69] Rigas E S, Ramchurn S D, Bassiliades N. Algorithms for electric vehicle scheduling in large-scale mobility-on-demand schemes[J]. *Artificial Intelligence*, 2018, 262: 248-278.
- [70] Falahati B, Fu Y, Darabi Z, et al. Reliability assessment of power systems considering the large-scale PHEV integration[C]. *Vehicle Power and Propulsion Conference*. Chicago: IEEE, 2011: 1-6.
- [71] Green R C, Wang L, Alam M, et al. Evaluating the impact of plug-in hybrid electric Vehicles on composite power system reliability[C]. *The 9th American Power Symposium (NAPS)*. Boston: IEEE, 2011: 1-7.
- [72] Misra S, Bera S, Ojha T. D2p: Distributed dynamic pricing policy in smart grid for phev management[J]. *IEEE Transactions on Parallel and Distributed Systems*, 2014, 26(3): 702-712.
- [73] Bayram I S, Michailidis G, Devetsikiotis M, et al. Electric power allocation in a network of fast charging stations[J]. *IEEE Journal on Selected Areas in Communications*, 2013, 31(7): 1235-1246.
- [74] Gao S, Chau K T, Liu C, et al. Integrated energy management of plug-in electric vehicles in power grid with renewables[J]. *IEEE Transactions on Vehicular Technology*, 2014, 63(7): 3019-3027.
- [75] Zheng Y, Li S, Tan R. Distributed model predictive control for on-connected microgrid power management[J]. *IEEE Transactions on Control Systems Technology*, 2017, 26(3): 1028-1039.
- [76] Clement-Nyns K, Haesen E, Driesen J. The impact of charging plug-in hybrid electric vehicles on a residential distribution grid[J]. *IEEE Transactions on Power Systems*, 2009, 25(1): 371-380.
- [77] Vandael S, Boucké N, Holvoet T, et al. Decentralized coordination of plug-in hybrid vehicles for imbalance reduction in a smart grid[C]. *The 10th International Conference on Autonomous Agents and Multiagent Systems*. Taipei: ACM, 2011: 803-810.
- [78] Stroe D I, Swierczynski M, Stroe A I, et al. Degradation behavior of lithiumion batteries based on lifetime models and field measured frequency regulation mission profile[J]. *IEEE Transactions on Industry Applications*, 2016, 52(6): 5009-5018.
- [79] Janfeshan K, Masoum M A S. Hierarchical supervisory control system for pevs participating in frequency regulation of smart grids[J]. *IEEE Power and Energy Technology Systems Journal*, 2017, 4(4): 84-93.
- [80] Saber A Y, Venayagamoorthy G K. Plug-in vehicles and renewable energy sources for cost and emission reductions[J]. *IEEE Transactions on Industrial Electronics*, 2010, 58(4): 1229-1238.
- [81] Zhang K, Mao Y, Leng S, et al. Platoon-based electric vehicles charging with renewable energy supply: A queuing analytical model[C]. *2016 International Conference on Communications (ICC)*. Kuala: IEEE, 2016: 1-6.
- [82] Quddus M A, Kabli M, Marufuzzaman M. Modeling electric vehicle charging station expansion with an integration of renewable energy and Vehicle-to-Grid sources[J]. *Transportation Research, Part E: Logistics and Transportation Review*, 2019, 128: 251-279.
- [83] Vu A, Farrell J A. Feature mapping and state estimation for highly automated vehicles[J]. *Journal of Control and Decision*, 2015, 2(1): 1-25.
- [84] Jia D, Lu K, Wang J. A disturbance-adaptive design for VANET-enabled vehicle platoon[J]. *IEEE Transactions on Vehicular Technology*, 2014, 63(2): 527-539.
- [85] Shladover S E, Desoer C A, Hedrick J K, et al. Automated vehicle control developments in the PATH program[J]. *IEEE Transactions on Vehicular Technology*, 1991, 40(1): 114-130.
- [86] Robinson T, Chan E, Coelingh E. Operating platoons on public motorways: An introduction to the sartre platooning programme[C]. *The 17th World Congress on Intelligent Transport System*. Busan: Transportation Research Records, 2010: 1-12.
- [87] Tsugawa S, Kato S. Energy ITS: another application of vehicular communications[J]. *IEEE Communications Magazine*, 2010, 48(11): 120-126.
- [88] Li L, Wen D, Yao D. A survey of traffic control with vehicular communications[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2013, 15(1): 425-432.

- [89] Zheng X, Chen W, Wang P, et al. Big data for social transportation[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2015, 17(3): 620-630.
- [90] Van de Hoef S, Johansson K H, Dimarogonas D V. Fuel-efficient en route formation of truck platoons[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2017, 19(1): 102-112.
- [91] Ploeg J, Van De Wouw N, Nijmeijer H. Lp string stability of cascaded systems: Application to vehicle platooning[J]. *IEEE Transactions on Control Systems Technology*, 2013, 22(2): 786-793.
- [92] Wang Q, Guo G, Cai B B. Distributed receding horizon control for fuel-efficient and safe vehicle platooning[J]. *Science China Technological Sciences*, 2016, 59(12): 1953-1962.
- [93] Zhang W, Jenelius E, Ma X. Freight transport platoon coordination and departure time scheduling under travel time uncertainty[J]. *Transportation Research, Part E: Logistics and Transportation Review*, 2017, 98: 1-23.
- [94] Hoef S V D, Johansson K H, Dimarogonas D V. Fuel-optimal centralized coordination of truck platooning based on shortest paths[C]. *Proceedings of the American Control Conference*. Chicago: IEEE, 2015: 3740-3745.
- [95] Van D H S, Johansson K H, Dimarogonas D V. Coordinating truck platooning by clustering pairwise fuel-optimal plans[C]. In *Proceedings of IEEE International Conference on Intelligent Transportation Systems*. Spain: IEEE, 2015: 408-415.
- [96] Liang K Y, Martensson J, Johansson K H. Heavy-duty vehicle platoon formation for fuel efficiency[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2016, 17(4): 1051-1061.
- [97] Meisen P, Seidl T, Henning K. A data mining technique for the planning and organization of truck platoons[C]. *Proceedings of International Conference on Heavy Vehicles*. Paris: John Wiley & Sons, 2008: 389-402.
- [98] Adler A, Miculescu D, Karaman S. Optimal policies for platooning and ride sharing in autonomy-enabled transportation[C]. *Workshop on Algorithmic Foundations of Robotics (WAFR)*. San Francisco: Springer, 2016: 1-10.
- [99] Guo G, Li D. Adaptive sliding mode control of vehicular platoons with prescribed tracking performance[J]. *IEEE Transactions on Vehicular Technology*, 2019, 68(8): 7511-7520.
- [100] Nemeth B, Gaspar P. Optimised speed profile design of a vehicle platoon considering road inclinations[J]. *IET Intelligent Transport Systems*, 2013, 8(3): 200-208.
- [101] Turri V, Besselink B, Johansson K H. Cooperative look-ahead control for fuel-efficient and safe heavy-duty vehicle platooning[J]. *IEEE Transactions on Control Systems Technology*, 2016, 25(1): 12-28.
- [102] Guo G, Li D. PMP-based set-point optimization and sliding-mode control of vehicular platoons[J]. *IEEE Transactions on Computational Social Systems*, 2018, 5(2): 553-562.
- [103] Guo G, Wang Q. Fuel-efficient en route speed planning and tracking control of truck platoons[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2019, 20(8): 3091-3103.
- [104] Wen S X, Guo G, Chen B, et al. Guaranteed cost control of networked systems with stochastic medium-access protocols: Methodology and applications[J]. *IET Control Theory & Applications*, 2019, 13(2): 258-268.
- [105] Swaroop D, Hedrick J K, Choi S B. Direct adaptive longitudinal control of vehicle platoons[J]. *IEEE Transactions on Vehicular Technology*, 2001, 50(1): 150-161.
- [106] Yanakiev D, Kanellakopoulos I. Nonlinear spacing policies for automated heavy-duty vehicles[J]. *IEEE Transactions on Vehicular Technology*, 1998, 47(4): 1365-1377.
- [107] Zhou J, Peng H. Range policy of adaptive cruise control vehicle for improved flow stability and string stability[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2005, 6(2): 229-237.
- [108] Santhanakrishnan K, Rajamani R. On spacing policies for highway vehicle automation[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2003, 4(4): 198-204.
- [109] 于晓海, 郭戈. 车队控制中的一种通用可变时距策略[J]. *自动化学报*, 2019, 45(7): 1335-1343.
(Yu X H, Guo G. A general variable time headway policy in platoon control[J]. *Acta Automatica Sinica*, 2019, 45(7): 1335-1343.)
- [110] Besselink B, Johansson K H. String stability and a delay-based spacing policy for vehicle platoons subject to disturbances[J]. *IEEE Transactions on Automatic Control*, 2017, 62(9): 4376-4391.
- [111] Ge G, Wen S X. Communication scheduling and control of a platoon of vehicles in VANETs[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2016, 17(6): 1551-1563.
- [112] Dolk V S, Ploeg J, Heemels W M H. Event-triggered control for string-stable vehicle platooning[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2017, 18(12): 3486-3500.
- [113] Huang S U, REN W. Design of vehicle following control systems with actuator delays[J]. *International Journal of Systems Science*, 1997, 28(2): 145-151.
- [114] Guo G, Yue W. Sampled-data cooperative adaptive cruise control of vehicles with sensor failures[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2014, 15(6): 2404-2418.
- [115] Lei C, Eenennaam E M V, Wolterink W K, et al. Impact of packet loss on CACC string stability performance[C]. *Proceedings of International Conference on ITS*

- Telecommunications. Russia: IEEE, 2011: 381-386.
- [116] Guo G, Yue W. Autonomous platoon control allowing range-limited sensors[J]. *IEEE Transactions on Vehicular Technology*, 2012, 61(7): 2901-2912.
- [117] Guo G, Yue W. Hierarchical platoon control with heterogeneous information feedback[J]. *IET Control Theory Application*, 2011, 5(15): 1766-1781.
- [118] Gao F, Li S E, Zheng Y, et al. Robust control of heterogeneous vehicular platoon with uncertain dynamics and communication delay[J]. *IET Intelligent Transport Systems*, 2016, 10(7): 503-513.
- [119] Shaw E, Hedrick J K. String stability analysis for heterogeneous vehicle strings[C]. *Proceedings of American Control Conference*. New York: IEEE, 2007: 3118-3125.
- [120] Dunbar W B, Caveney D S. Distributed receding horizon control of vehicle platoons: Stability and string stability[J]. *IEEE Transactions on Automatic Control*, 2012, 57(3): 620-633.
- [121] Ma Y, Li Z, Malekian R, et al. Hierarchical fuzzy logic-based variable structure control for vehicles platooning[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2019, 20(4): 1329-1340.
- [122] Liu H, Rai L, Wang J, et al. A new approach for real-time traffic delay estimation based on cooperative vehicle-infrastructure systems at the signal intersection[J]. *Arabian Journal for Science & Engineering*, 2019, 44: 1-13.
- [123] Jiang Y, Li S, Shamo D E. A platoon-based traffic signal timing algorithm for major-minor intersection types[J]. *Transportation Research, Part B: Methodological*, 2006, 40(7): 543-562.
- [124] Weinert F, Düring M. Development and assessment of cooperative V2X applications for emergency vehicles in an urban environment enabled by behavioral models[M]. Berlin: Springer, 2015: 125-153.
- [125] Khan A, Ullah F, Kaleem Z, et al. EVP-STC: Emergency vehicle priority and self-organising traffic control at intersections using Internet-of-things platform[J]. *IEEE Access*, 2018, 6: 68242-68254.
- [126] Yao J, Zhang K, Yang Y, et al. Emergency vehicle route oriented signal coordinated control model with two-level programming[J]. *Soft Computing*, 2018, 22(13): 4283-4294.
- [127] Ji Y, Zhang X, Tang Y, et al. Coordinated optimization of tram trajectories with arterial signal timing resynchronization[J]. *Transportation Research, Part C: Emerging Technologies*, 2019, 99: 53-66.
- [128] Wu W, Ma W, Long K, et al. Designing sustainable public transportation: Integrated optimization of bus speed and holding time in a connected vehicle environment[J]. *Sustainability*, 2016, 8(11): 1170-1184.
- [129] Kim H, Cheng Y, Chang G L. Variable signal progression bands for transit vehicles under dwell time uncertainty and traffic queues[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2018, 20(1): 109-122.
- [130] Truong L T, Currie G, Wallace M, et al. Coordinated transit signal priority model considering stochastic bus arrival time[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2018, 20(4): 1269-1277.
- [131] Zhao J, Zhou X. Improving the operational efficiency of buses with dynamic use of exclusive bus lane at isolated intersections[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2018, 20(2): 642-653.
- [132] He Q, Head K L, Ding J. PAMSCOD: Platoon-based arterial multi-modal signal control with online data[J]. *Transportation Research, Part C: Emerging Technologies*, 2012, 20(1): 164-184.
- [133] Zhao J, Li W, Wang J, et al. Dynamic traffic signal timing optimization strategy incorporating various vehicle fuel consumption characteristics[J]. *IEEE Transactions on Vehicular Technology*, 2015, 65(6): 3874-3887.
- [134] Li W, Ban X. Connected vehicles based traffic signal timing optimization[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2018, DOI: 10.1109/TITS.2018.2883572.
- [135] Chen L W, Chang C C. Cooperative traffic control with green wave coordination for multiple intersections based on the internet of vehicles[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2016, 47(7): 1321-1335.
- [136] Asadi B, Vahidi A. Predictive cruise control: Utilizing upcoming traffic signal information for improving fuel economy and reducing trip time[J]. *IEEE Transactions on Control Systems Technology*, 2011, 19(3): 707-714.
- [137] Li S E, Xu S, Huang X, et al. Eco-departure of connected vehicles with V2X communication at signalized intersections[J]. *IEEE Transactions on Vehicular Technology*, 2015, 64(12): 5439-5449.
- [138] Zhang J, Dong S, Li Z, et al. An eco-driving signal control model for divisible electric platoons in cooperative vehicle-infrastructure systems[J]. *IEEE Access*, 2019, 7: 83277-83285.
- [139] He X, Liu H X, Liu X. Optimal vehicle speed trajectory on a signalized arterial with consideration of queue[J]. *Transportation Research, Part C: Emerging Technologies*, 2015, 61: 106-120.
- [140] Yang H, Rakha H, Ala M V. Eco-cooperative adaptive cruise control at signalized intersections considering queue effects[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2017, 18(6): 1575-1585.
- [141] Conceição H, Damas L, Ferreira M, et al. Large-scale simulation of V2V environments[C]. *Proceedings of the 2008 ACM Symposium on Applied Computing*. New York: ACM, 2008: 28-33.
- [142] Fathollahnejad N, Villani E, Pathan R, et al. On reliability

- analysis of leader election protocols for virtual traffic lights[C]. The 43rd Annual IEEE/IFIP Conference on Dependable Systems and Networks Workshop (DSN-W). Budapest: IEEE, 2013: 1-12.
- [143] Lee J, Park B. Development and evaluation of a cooperative vehicle intersection control algorithm under the connected vehicles environment[J]. IEEE Transactions on Intelligent Transportation Systems, 2012, 13(1): 81-90.
- [144] Chen W, Liu Y. Gap-based automated vehicular speed guidance towards eco-driving at an unsignalized intersection[J]. Transportmetrica B: Transport Dynamics, 2019, 7(1): 147-168.
- [145] Saiáns-Vázquez J, Ordóñez-Morales E, López-Nores M, et al. Intersection intelligence: Supporting urban platooning with virtual traffic lights over virtualized intersection-based routing[J]. Sensors, 2018, 18(11): 4054-4064.
- [146] Bichiou Y, Rakha H A. Developing an optimal intersection control system for automated connected vehicles[J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 20(5): 1908-1916.
- [147] Zhao W, Liu R, Ngoduy D. A bilevel programming model for autonomous intersection control and trajectory planning[J]. Transportmetrica A: Transport Science, 2018, DOI: 10.1080/23249935.2018.1563921.
- [148] Belkhouche F. Collaboration and optimal conflict resolution at an unsignalized intersection[J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 20(6): 2301-2312.
- [149] Fayazi S A, Vahidi A, Luckow A. Optimal scheduling of autonomous vehicle arrivals at intelligent intersections via MILP[C]. American Control Conference (ACC). Seattle: IEEE, 2017: 4920-4925.
- [150] Guo Y, Ma J, Xiong C, et al. Joint optimization of vehicle trajectories and intersection controllers with connected automated vehicles: Combined dynamic programming and shooting heuristic approach[J]. Transportation Research, Part C: Emerging Technologies, 2019, 98: 54-72.
- [151] Xu B, Ban X J, Bian Y, et al. Cooperative method of traffic signal optimization and speed control of connected vehicles at isolated intersections[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 20(4): 1390-1403.
- [152] Hou Y, Seliman S M S, Wang E, et al. Cooperative and integrated vehicle and intersection control for energy efficiency (CIVIC-E 2)[J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 19(7): 2325-2337.
- [153] Yu C, Feng Y, Liu H X, et al. Integrated optimization of traffic signals and vehicle trajectories at isolated urban intersections[J]. Transportation Research, Part B: Methodological, 2018, 112: 89-112.
- [154] Feng Y, Yu C, Liu H X. Spatiotemporal intersection control in a connected and automated vehicle environment[J]. Transportation Research, Part C: Emerging Technologies, 2018, 89: 364-383.
- [155] De Nunzio G, Gomes G, Canudas-de-Wit C, et al. Speed advisory and signal offsets control for arterial bandwidth maximization and energy consumption reduction[J]. IEEE Transactions on Control Systems Technology, 2016, 25(3): 875-887.
- [156] Zhang T Q, Hao L Y, Guo G. A feature enriching object detection framework with weak segmentation loss[J]. Neurocomputing, 2019, 35: 72-80.
- [157] Zhang L, Hu T, Min Y, et al. A taxi order dispatch model based on combinatorial optimization[C]. The 23rd ACM SIGKDD International Conference. Halifax: ACM, 2017: 2151-2159.
- [158] Guo G, Wang L Y. Control over medium-constrained vehicular networks with fading channels and random access protocol: A networked systems approach[J]. IEEE Transactions on Vehicular Technology, 2015, 64(8): 3347-3358.
- [159] Guo G, Wen S X. Sampled-data control for connected vehicles with markovian switching topologies and communication delay[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, DOI: 10.1109/TITS.2019.2921781.
- [160] Van Mierlo J, Maggetto G. Understanding individual human mobility patterns[J]. Nature, 2008, 453: 779-782.

作者简介

郭戈(1972—), 男, 教授, 博士生导师, 从事网联车辆协同控制、智能交通系统、共享出行系统优化与控制等研究, E-mail: geguo@yeah.net;

许阳光(1989—), 男, 博士生, 从事共享出行系统的研究, E-mail: shine216831@sina.com;

徐涛(1996—), 男, 硕士生, 从事共享出行系统的研究, E-mail: 18716039252@163.com;

李丹丹(1990—), 女, 博士生, 从事网联车辆协同控制的研究, E-mail: 2453663715@qq.com;

王云鹏(1991—), 男, 博士生, 从事车路协同控制研究, E-mail: yunpengwang0306@163.com;

袁威(1996—), 男, 硕士生, 从事大数据与交通预测的研究, E-mail: 2804369243@qq.com.

(责任编辑: 郑晓蕾)