

智能交通信息物理融合云控制系统

夏元清¹ 闫策¹ 王笑京² 宋向辉²

摘要 针对现代智能交通信息物理融合路网建设中的对象种类复杂、采集数据量大、传输及计算需求高以及实时调度控制能力弱等问题, 基于云控制系统理论, 以现代智能交通控制网络为研究对象, 设计了智能交通信息物理融合云控制系统方案, 包括智能交通边缘控制技术和智能交通网络虚拟化技术。基于智能交通流大数据, 在云控制管理中心服务器上利用深度学习和超限学习机等智能学习方法对采集的交通流数据进行训练预测计算, 能够预测城市道路的短时交通流和拥堵状况。进一步在云端利用智能优化调度算法得到实时的交通流调控策略, 用于解决拥堵路段交通流分配难题, 提高智能交通控制系统动态运行性能。仿真结果表明了本文方法的有效性。

关键词 智能交通云控制系统, 深度学习, 超限学习, 信息物理融合系统

引用格式 夏元清, 闫策, 王笑京, 宋向辉. 智能交通信息物理融合云控制系统. 自动化学报, 2019, 45(1): 132–142

DOI 10.16383/j.aas.c180370

Intelligent Transportation Cyber-physical Cloud Control Systems

XIA Yuan-Qing¹ YAN Ce¹ WANG Xiao-Jing² SONG Xiang-Hui²

Abstract Based on the theory of cloud control systems, an intelligent transportation cyber-physical cloud control system is designed due to the problems of complex objects, big data, high demand for transmission and calculation and poor real-time control ability in the modern intelligent transportation cyber-physical network. It includes intelligent transportation edge control technology and intelligent transportation network virtualization technology. Based on the big data of intelligent traffic flow, two intelligent learning methods, deep learning and extreme learning machine, are used to train and predict the traffic flow data on the servers of the cloud control management center. The short time traffic flow and the congestion of roads are predicted accurately. Then the real-time traffic flow control strategy is obtained by intelligent optimization scheduling algorithm in the cloud. The problem of traffic flow distribution in congested roads is solved and the dynamic performance of intelligent transportation control systems can be improved. The simulation results show the effectiveness of the proposed method.

Key words Intelligent transportation cloud control systems, deep learning, extreme learning machine, cyber-physical systems

Citation Xia Yuan-Qing, Yan Ce, Wang Xiao-Jing, Song Xiang-Hui. Intelligent transportation cyber-physical cloud control systems. *Acta Automatica Sinica*, 2019, 45(1): 132–142

信息物理融合系统 (Cyber-physical systems,

CPS) 是多维异构的物理对象在网络环境中高度集成交互的新型智能复杂系统^[1], 集成计算、通信和控制技术于一体的信息物理融合系统为新一代智能交通系统提供了可行的解决方案和先进技术, 解决智能交通系统的智能优化调度、目标实时控制等问题。新一代智能交通系统是信息物理融合系统的关键发展方向。同时迅猛发展的云计算技术可以解决大规模智能交通控制系统中大数据计算和优化控制调度算法密集运行难题。云计算的基本原理是, 通过使计算任务分布在大量的云端分布式计算机上, 使得智能交通管理部门能够将云计算资源匹配到智能交通云控制的应用上, 根据需求访问计算机和存储系统^[2]。信息物理融合系统及云计算等相关技术的应用使交通数据实时获取传输及计算处理成为可能, 应用动态矩阵模型和人工智能算法可以提前预测下一时刻的交通流数据。

收稿日期 2018-06-01 录用日期 2018-08-27

Manuscript received June 1, 2018; accepted August 27, 2018
国家重点研发计划 (2018YFB1003700), 国家自然科学基金 (61836001, 61803033), 国家自然科学基金国际合作交流项目 (61720106010), 国家自然科学基金创新研究群体基金 (61621063), 北京市自然科学基金 (4161001, Z170039) 资助

Supported by National Key Research and Development Program of China (2018YFB1003700), National Natural Science Foundation (61836001, 61803033), National Natural Science Foundation Projects of International Cooperation and Exchanges (61720106010), Foundation for Innovative Research Groups of the National Natural Science Foundation of China (61621063), Beijing Natural Science Foundation (4161001, Z170039)

本文责任编辑 贺威

Recommended by Associate Editor HE Wei

1. 北京理工大学自动化学院复杂系统智能控制与决策国家重点实验室 北京 100081 2. 交通运输部公路科学研究院 北京 100082

1. School of Automation, Key Laboratory of Intelligent Control and Decision of Complex Systems, Beijing Institute of Technology, Beijing 100081 2. Research Institute of Highway Ministry of Transport, Beijing 100082

本文基于以上最新技术综合设计提出智能交通信息物理融合云控制系统 (Intelligent transportation cyber-physical cloud control systems, ITPCPCS). 图 1 展示了智能交通云控制体系以及相关信息物理融合技术, 应用的核心在于为行驶者、交通工具、交通基础设施建立起以身份信息为核心、唯一对应的标识. 然后基于数据采集、传感器、网络传输等技术, 将获取的动态信息即时发送到智能交通网络综合数据处理云控制平台上, 再通过云控制平台对获取的信息数据系统性、智能化处理运算, 得到系统预测结果以及调控方案, 然后发送到智能交通终端, 实现对整个智能交通路网的统一监控、管理、决策和控制服务. 通过 WIFI、5G 移动数据等通信方式将车辆与道路边缘控制服务器 (Mobile edge control, MEC) 相连接, 同时交通终端也可与云端进行直接通信, 使智能交通云控制管理平台实时感知车辆排队、堵塞、事故以及信号灯等交通状况, 进行分析、优化、预测、决策与控制, 并且使无人车、有人车驾驶员等实时获得实时路况信息, 调整合适的路径选择行为.

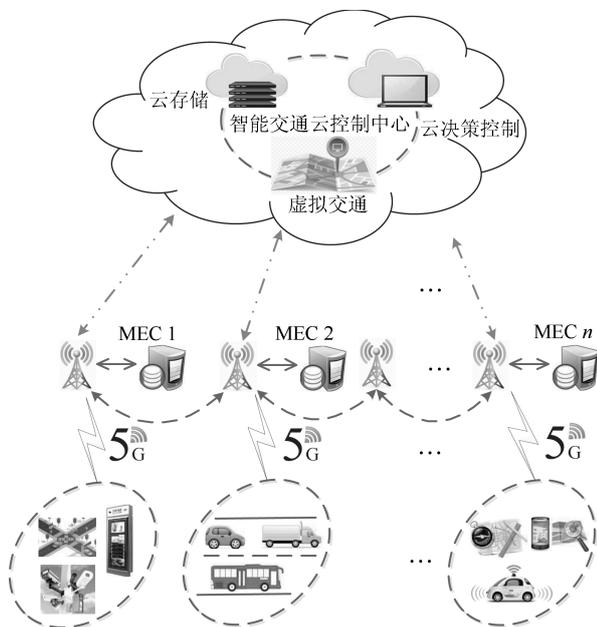


图 1 智能交通云控制系统示意图

Fig. 1 Schematic diagram of intelligent transportation cloud control systems

智能交通信息物理融合云控制系统包括交通大数据云计算、交通流智能预测、交通流云控制调度等核心技术. 其中云控制的核心思想是将大量用网络连接的计算资源统一管理和调度, 构成一个计算资源池向交通路网设备以及终端用户提供按需服务^[3-4]. 交通信息云是由云计算和智能交通信息云服务构成的信息全过程, 是一种交通信息采集、处

理和应用的工作模式^[5]. 文献 [6] 基于社会交通、计算实验和平行执行智能机器系统, 提出了基于信息物理社会系统的平行驾驶框架, 详细论述了平行测试、平行学习以及平行增强学习等方法在智能网联汽车的感知、决策与规划和控制等关键模块中的应用. 通过挖掘采集数据的特征, 以提高数据采集、传输、预处理和估算的精度和效率, 为智能交通云控制系统提供高质量、完备、实时的交通数据^[7]. 城市智能交通诱导控制系统的结构复杂, 城市交通问题求解的计算量巨大, 采用多智能体技术能够将复杂系统问题分解, 降低计算复杂性, 更易于处理^[8-9]. 由于实际路网和交通用户的需求, 短时交通流预测的结果更能满足实时性的需要^[10-12].

近年来, 人工智能算法的飞速发展使得对于具有非线性特征的交通数据处理进入了一个新的发展阶段^[13-14], 人工智能模型可以在自学习的过程中, 以自适应调节模型参数的方法获取数据的本质特征来达到更优的预测效果^[15-17]. 这种预测模型主要有神经网络 (Neural network, NN) 模型^[18]、支持向量机 (Support vector machine, SVM) 模型^[19]等. 深度学习作为一种新的机器学习方法开始受到研究人员的高度关注, 并且在一些领域中取得了成功的应用^[19-20]. 目前应用深度学习来进行交通预测已经有了一些相关研究成果, Huang^[20] 等应用了基于深信网络模型结构和多任务回归的交通预测方法, 对单输出和多任务输出的流量进行了预测. 针对智能交通流大数据, 深度学习能够通过底层的特征组合, 抽象高层特征来实现数据的分布式表示, 从而可以更好地刻画出数据的本质特征^[21-23]. 谭娟等^[24] 将深度学习应用到交通拥堵预测研究中. Lv 等^[25] 针对大路网下的交通流, 提出了自编码的深度网络模型预测方法. Huang 等^[26] 提出了一种在训练过程中能够随机产生隐含层节点数的超限学习机 (Extreme learning machine, ELM) 算法. 2012 年, 在深入研究支持向量机 (SVM) 的基础上, Huang 等将核函数引入到超限学习机中^[27], 获取最小平方优化解, 使得超限学习机具有更稳定的泛化性能. 深度学习与超限学习在不同的数据样本集训练预测上各有优势. 根据得到的交通流准确预测数据, 可提前预判出道路的通行和拥堵情况, 利用云端优化控制调度算法对交通流进行实时调控.

在基于云控制理论建立的智能交通信息物理融合云控制系统研究中, 本文将在云端采用国际前沿的人工智能机器学习算法, 对智能交通系统 (Intelligent transportation systems, ITS) 交通大数据进行精准处理, 实现交通系统短时交通流快速预测, 为交通路网系统智能控制提供预测数据保障^[28].

本文主要贡献有: 1) 面向交通控制网络智能化

发展的技术需求,首次提出智能交通信息物理融合云控制系统设计方案,给出了云控制理论在智能交通领域的示范性应用. 2) 针对智能交通信息物理融合云控制系统的实现问题,基于云计算和人工智能等技术,提出了智能交通边缘控制技术、智能交通网络虚拟化技术、交通流云端智能预测技术. 3) 为解决智能交通系统中的云端交通数据处理的难题,引入了深度信念网络支持向量回归算法 (Deep belief network support vector regression, DBN-SVR) 并且提出基于反向传播的双端超限学习机算法 (Back propagation bilateral extreme learning machine, BP-BELM), 实现了智能交通云控制系统的短时交通流精准预测. 4) 针对智能交通路网大规模交通流调控的难题,在云端设计了智能交通信息物理融合云控制系统预测交通流分配方案,进行基于交通流短时预测大数据的优化调度.

1 智能交通信息物理融合云控制系统设计

在实际智能交通信息物理融合控制系统中,云控制系统能够提供一个可配置资源的共享池,其中包括智能计算、软件、交通大数据访问和存储服务,终端用户无需知道服务提供者的物理位置和具体配置就能进行使用. 随着云计算系统的处理能力不断提高,可以减少智能交通控制网络区域系统的处理负担. 由于云控制系统综合了云计算的优势、

网络控制系统的先进理论和其他近期发展的相关结果^[29-30],能够为智能交通控制提供最新的技术支持. 如图 2 所示,将交通需求调度与云计算、云控制闭环反馈以及边缘控制设计方法相结合,采用智能交通大数据分析、协调控制、资源调度等技术,能够实现智能交通的云端智能决策、云端协同控制以及与人机交互的有机整合. 在智能交通信息物理融合云控制方案设计过程中,我们提出边缘控制技术、软件定义交通虚拟化技术、交通大数据分析技术和交通流优化调度技术. 建立云端智能计算决策和基于边缘计算的边缘闭环控制相协作的交互机制,来实现智能交通信息物理融合云控制系统的整体建立.

目前云计算体系中有基础设施即服务 (Infrastructure as a service, IaaS)、平台即服务 (Platform as a service, PaaS) 和软件即服务 (Software as a service, SaaS) 三种服务模型. 智能交通信息物理融合云控制系统将交通大数据存储在云端,利用云计算能力,实现云端对系统的优化、决策、调度、计划、预测及控制. 从控制视角分析,智能交通信息物理融合系统的复杂性使得难以对其进行建模. 云端和终端间网络时延以及网络带宽饱和会使系统无法实时处理海量数据,造成系统性能的损失. 为解决这两个难题,可利用云控制与边缘控制结合的云端协同控制方式,提高控制系统实时性和可用性,实现控制即服务 (Control as a service, CaaS) 的目的.

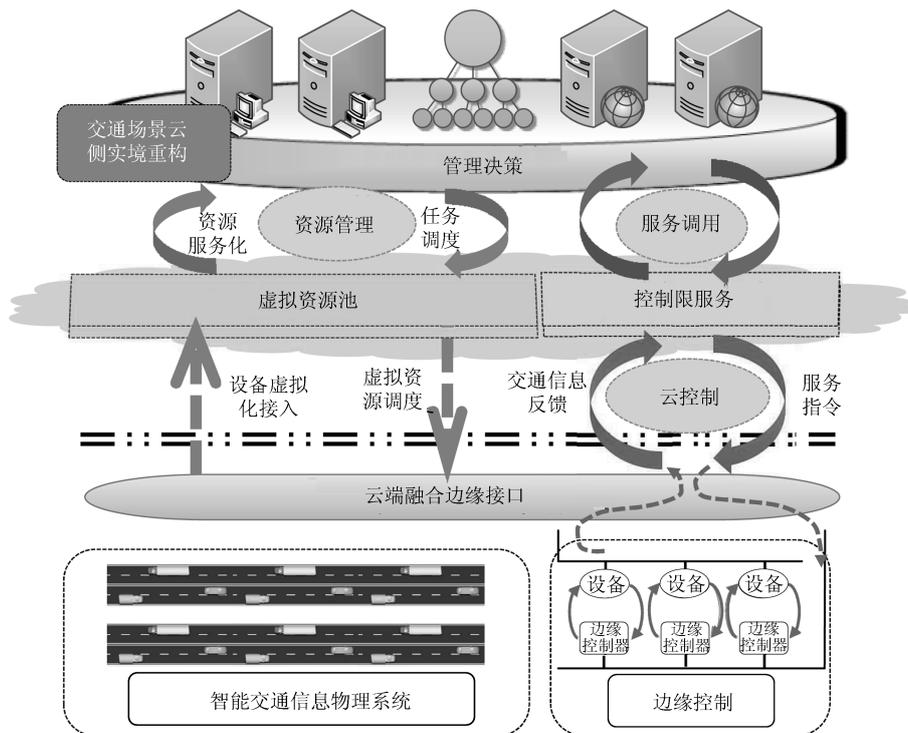


图 2 面向交通需求的交通云端协同控制

Fig. 2 Cloud coordination control for traffic demand

CaaS 面向系统管理员、开发人员、系统普通用户, 用户可以从供应商那里获得所需要的虚拟机或者存储等资源来装载相关的控制计算软件. CaaS 同时提供给用户包含基础操作系统、专业控制软件、网络和存储等配置的控制开发平台, 具有极高的系统整合率和经济性. 另外, 任何一个远程终端上的控制应用都可以通过网络来运行. 用户只要接上网络, 通过浏览器就能调节修改运行在云端上的控制器, 免去高昂的硬件投入. 控制终端将控制系统采集数据上传到云端, 云控制器通过计算得到所需的控制系统参数和调节指令. 对于系统模型不确定的控制终端, CaaS 可依托强大的数据存储和计算能力, 利用智能学习算法为控制终端提供数据驱动模型优化学习、模型预测控制、故障诊断与系统维护以及控制系统优化调度决策等服务. 对于系统模型确定的控制终端, CaaS 可根据控制算法和实时上传的系统数据, 提供控制算法资源池优化和控制参数实时自动调节服务, 为实际控制系统省去专业调试维护人员. CaaS 能够保证控制系统数据的完整性、可靠性和可管理性, 能更好地调度和管理控制系统, 保证其高效运行. CaaS 平台会以 API 的形式将各种各样的控制服务集成提供给用户, 采用多用户机制, 能够支撑庞大的控制终端规模, 并且提供定制化服务以满足用户的特殊需求.

1.1 智能交通边缘控制技术

在智能交通信息物理融合云控制系统整体框架中, 我们提出了边缘控制技术. 边缘控制即充分利用终端边缘计算的优势, 无需将系统数据传输到云端进行云决策就可在本地或小区域范围内对具体系统进行控制, 可提高终端控制的实时性. 如图 3 所示, 在智能交通云控制系统中边缘控制和智能云端进行融合, 并且边缘控制包含多方面的控制问题, 面对不同的系统对象, 控制形式不同. 在现代智能交通网络中, 实际控制对象主要包括: 交通车辆用户终端、无人车(如谷歌 Waymo 无人车、百度百智无人车)、交通灯、道路摄像头终端、道路传感器终端等设备.

面向智能交通底层设备终端的边缘控制系统, 核心是基于交通设备运行数据和对交通环境的实时感知, 并利用边缘计算方法设计交通设备具体控制策略, 实现底层交通设备本地边缘控制, 例如交通灯控制、无人车控制、交通摄像头控制和本地区域用户导航设备控制等. 边缘控制在智能交通云控制系统中为云端控制提供局部信息, 是控制智能交通终端设备实时运行的关键. 云控制系统为多个边缘控制设备提供全局控制策略, 统筹整个智能交通网络, 二者相互协作才能保证智能交通云控制系统良好运行.

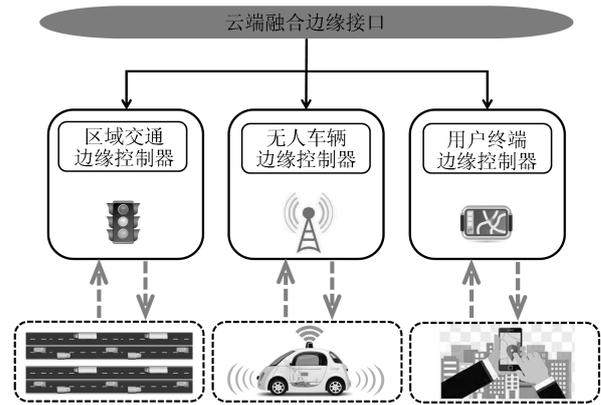


图 3 智能交通底层边缘控制

Fig. 3 Intelligent transportation bottom edge control

1.2 智能交通网络虚拟化技术

智能交通网络虚拟化技术, 可将物理交通网络虚拟成由多个虚拟交通子网络组成的虚拟交通网络. 核心思想是应用虚拟化软件对交通网络进行控制管理, 通过自动化部署功能简化交通云端计算运维. 如图 4, 智能交通云控制网络相互耦合的整体架构可被拆分成云控制平台、虚拟化平台、物理应用平台三层架构.

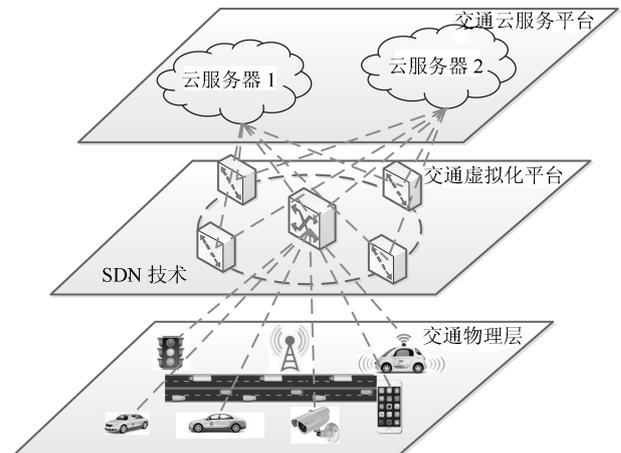


图 4 智能交通云控制网络虚拟化架构

Fig. 4 Intelligent transportation cloud control network virtualization architecture

该架构中数据计算和决策控制功能部署在云端服务器. 利用交通网络虚拟化平台, 底层交通应用设施在云端依据实际物理交通规律被抽象成多个逻辑实体. 智能交通云管理者看到的是虚拟化平台提供的程序化交通网络. 这样云端服务可与物理交通网络解耦, 便于云端资源的灵活部署和快速业务供应. 随着信息物理融合系统的发展, 软件定义技术开始向物理世界延伸, 在智能交通云控制系统中我们提出软件定义交通 (Software defined transportation,

SDT) 技术, 利用智能软件对智能交通网络拓扑进行定义和映射, 把智能交通系统中的各类信息设备、物理基础设施进行虚拟化定义, 达到开放共享和互联互通的目的, 实现智能交通云端精细化管理. SDT 技术的本质是交通硬件资源虚拟化、管理对象和管理功能可编程化实现. 传统交通物理设施抽象为虚拟资源, 利用云端部署软件对虚拟交通进行计算和调度决策. 该技术可实现交通物理层和云端计算层的合理分离, 利用程序软件即可保证虚拟化映射的完整性和准确性, 又可满足交通任务多样性的需求.

2 交通流云端智能预测技术

交通流预测是智能交通云控制系统的关键技术, 云端交通流预测调度系统是智能交通信息物理融合云控制系统的大脑中枢. 通过对智能交通云控制数据中心的数据预测分析, 云控制服务平台可对交通的拥堵情况、路面的行驶状态以及车辆的实时行驶速度进行综合控制处理. 针对大型路网的大规模交通流数据, 本文研究基于 DBN-SVR 的路网短时交通流云端预测方法, 并且与基于 BP-BELM 的短时交通流云端预测方法进行比较分析.

2.1 基于 DBN-SVR 的短时交通流预测算法

针对大规模交通流数据, 本文给出了基于深度学习结合支持向量回归的预测模型. 所用的 DBN 模型是一个含有三个隐含层的网络模型结构, 如图 5 所示. 其中最底层节点表示训练数据, 最上层节点表示预测输出数据.

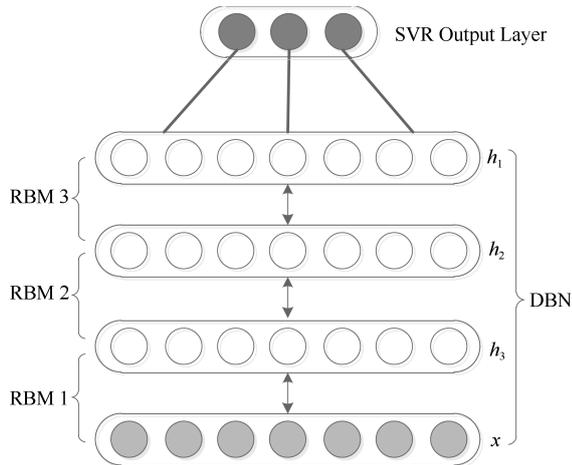


图 5 DBN-SVR 模型网络结构

Fig. 5 Network structure of DBN-SVR model

由于各个路段的交通流之间具有时间、空间上的关联性, 设预测模型的输入数据集为 X_t , 则有

$$X_t = \{x_1, x_2, \dots, x_p\} \quad (1)$$

$$x_i = \{x_{i,t}, x_{i,t-\Delta t}, \dots, x_{i,t-M\Delta t}\} \quad (2)$$

其中: $i = 1, 2, \dots, p$, p 表示数据列数, M 表示数据采集间隔数, $x_{i,t}$ 表示第 i 个路段在 t 时刻的交通流量, Δt 表示数据时间间隔. 任意一个路段的下一时刻的流量由相邻几个路段当前时刻和前 M 个时刻的交通流量数据来进行预测. 假设输入数据集通过 DBN 模型特征学习后的输出向量为 H , 则有

$$H = \Phi(X_d) \quad (3)$$

其中 Φ 表示深度学习 DBN 网络模型, X_d 为按照 $x_{i,t}^d = x_{i,t} - x_{i,t-d}$ 式处理后的交通流数据集.

SVR 是具有隐藏单元的非线性前馈网络, 能够实现和时间序列的预测处理. 所用非线性回归函数如下:

$$f(x) = \sum_{i=1}^l \alpha_i^* y_i K(x_i, x) + b^*$$

其中 $K(x_i, x) = (\Phi(x_i), \Phi(x))$ 为核函数, α_i^* 为正分量值, b^* 为阈值, y_i 为训练集输出值.

由此得出任意一个路段 j 在 $t + \Delta t$ 时刻的交通流预测值为

$$y_d(j, t + \Delta t) = f(H) \quad (4)$$

其中 f 是支持向量机 (SVR) 预测模型, $y_d(j, t + \Delta t)$ 为第 j 个路段在 $t + \Delta t$ 时刻的交通流, $j = 1, 2, \dots, p$.

具体的交通流预测算法流程如下:

- 根据交通流数据的特征, 由式 (1)、(2) 构造输入数据集 X_t ;
- 根据式 $x_{i,t}^d = x_{i,t} - x_{i,t-d}$ 对交通流数据集进行预处理得到残差量 X_d ;
- 以 X_d 作为 DBN 网络模型输入进行特征学习, 由式 (3) 得到交通流特征 H ;
- 以 H 为输入, 根据式 (4), 利用 SVR 预测模型进行交通流数据预测;
- 由式 $\hat{x}_{i,t+1} = \hat{x}_{i,t+1}^d + \hat{x}_{i,t-d+1}$ 进行原始交通流数据还原计算, 求出实际交通流预测值.

2.2 基于 BP-BELM 的短时交通流预测算法

本文提出了基于反向传播的双端超限学习机算法 (BP-BELM), 利用该算法对智能交通流数据进行实时精准预测. 该算法采用网络余差反向传播的方式计算部分隐含层节点的最优参数, 以增强 ELM 算法的稳定性.

如图 6 所示, 基于反向传播的双端超限学习机算法 (BP-BELM) 进行隐含层节点数奇偶划分, 其节点参数通过网络余差反向传播的方式计算获得.

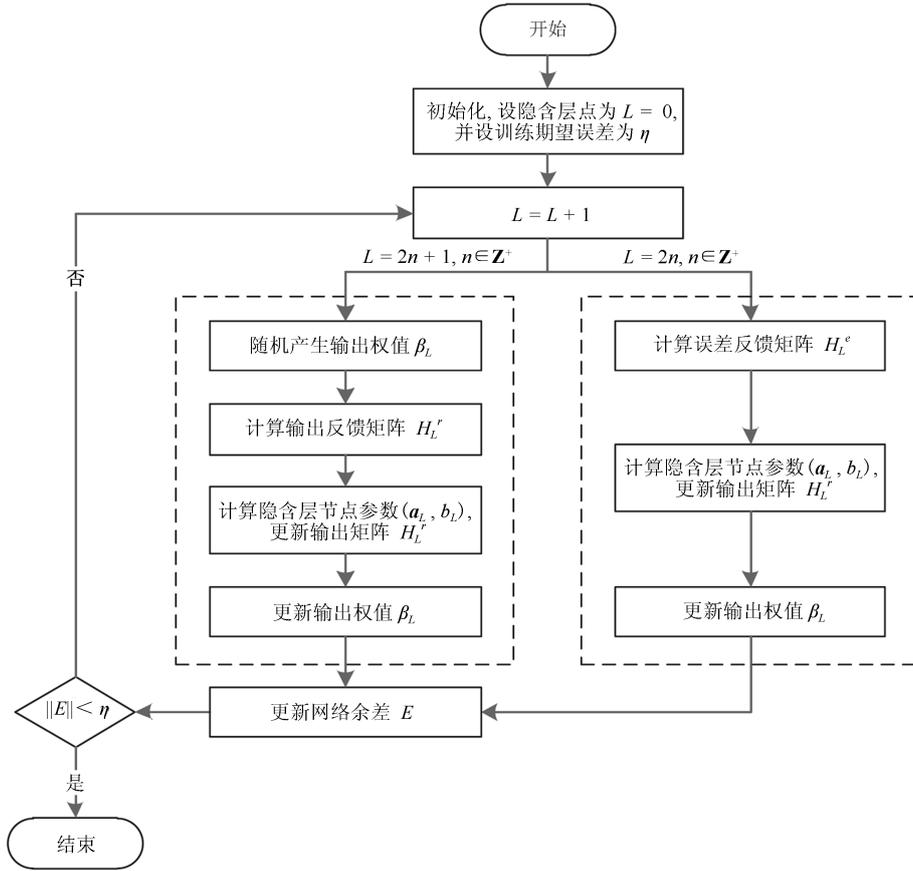


图 6 基于反向传播的双端超限学习机算法流程图

Fig. 6 Algorithm flow chart of back propagation bilateral extreme learning machine

给定神经网络的训练样本 $\phi = (x_i, y_i)_{i=1}^N \in \mathbf{R}^m \times \mathbf{R}^n$, 隐含层节点的激励函数 $h: \mathbf{R} \rightarrow \mathbf{R}$, 最大隐含层节点数 L_{\max} , 期望精度为 ε , 具有 $L-1$ 个隐含层节点的网络训练误差为 e_{L-1} , x_i 为输入, y_i 为输出. 基于反向传播的双端超限学习机算法的训练步骤如下所示:

第 1 步, 神经网络初始化阶段: 令 $L = 0$, 初始网络误差为 $E = Y$, 其中 $Y = [y_1, y_2, \dots, y_N]^T$.

第 2 步, 神经网络训练阶段: 当 $L < L_{\max}$ 且 $\|E\| > \varepsilon$ 时, 增加一个隐含层节点 $L: L = L + 1$; 若 $L = 2n + 1, n \in \mathbf{Z}^+$;

- 随机产生新增隐含层节点的输出权值 β_L ;
- 计算输出反馈矩阵: $H_L^r = e_{L-1}(\beta_L)^{-1}$;
- 计算隐含层节点参数:

$$a_L = x^T(I + xx^T)^{-1} \cdot h^{-1}(u(H_L^r))$$

$$b_L = \frac{\sum(a_L \cdot x - h^{-1}(u(H_L^r)))}{N}$$

d) 更新输出权值矩阵: $\hat{H}_L^r = u^{-1}(h(a_L \cdot x + b_L))$;

e) 根据最小二乘法计算更新后的新增隐含层节

点的输出权值:

$$\hat{\beta}_L = \frac{E \cdot (\hat{H}_L^r)^T}{(\hat{H}_L^r) \cdot (\hat{H}_L^r)^T}$$

f) 计算神经网络在增加了第 L 个隐含层节点后的误差: $E = E - \hat{\beta}_L \cdot \hat{H}_L^r$;

结束.

若 $L = 2n, n \in \mathbf{Z}^+$;

a) 计算输出反馈矩阵: $H_L^e = e_{L-1}(\hat{\beta}_{L-1})^{-1}$;

b) 计算隐含层节点参数:

$$a_L = x^T(I + xx^T)^{-1} \cdot h^{-1}(u(H_L^e))$$

$$b_L = \frac{\sum(a_L \cdot x - h^{-1}(u(H_L^e)))}{N}$$

c) 更新输出权值矩阵: $\hat{H}_L^r = u^{-1}(h(a_L \cdot x + b_L))$;

d) 根据最小二乘法计算更新新增隐含层节点的输出权值:

$$\hat{\beta}_L = \frac{E \cdot (\hat{H}_L^r)^T}{(\hat{H}_L^r) \cdot (\hat{H}_L^r)^T}$$

e) 计算神经网络在增加了第 L 个隐含层节点后的误差: $E = E - \hat{\beta}_L \cdot \hat{H}_L^T$;
结束.

3 智能交通信息物理融合云控制系统调度

基于云控制系统理论中的预测控制思想, 针对交通路网权值矩阵, 根据前文提出的云端人工智能短时预测数据, 利用求解得到的最短路径对用户出行路径进行诱导规划, 结合交通流分配方法设计智能交通云控制系统预测调度方案, 可实现对交通流的云端滚动预测实时控制.

如图 7 所示, 图中 O 到 D 的折线路径是最短路径. 由于道路交通的时变特性, 将交通流分配调控程序在云端进行以 5 分钟为间隔的循环更新运算, 保证最短路径和交通流分配的实时性. 交通阻抗作为交通流分配中的一项重要指标, 直接影响道路出行者路径的选择和路网中流量的分配. 路段阻抗函数可对交通阻抗进行精确描述, 是路段行驶时间与路段流量, 交叉口延误与交叉口流量之间的关系. 在具体的流量分配过程中, 交通阻抗是由路段行驶时间和交叉口延误共同组成的. 假设车辆通过一条路段, 需要的出行时间即路段阻抗为 t , 则路段阻抗函数为:

$$t_a = \begin{cases} 2t_0 \left(1 + \sqrt{1 - \frac{z_a}{c_a}}\right)^{-1} + T_a, & Z_a \leq c_a \\ 2t_0 \left(1 - \sqrt{1 - \frac{z_a}{c_a}}\right)^{-1} + T_a, & Z_a > c_a \end{cases}$$

其中, t_0 是零流阻抗, 即路段流量为零时车辆行驶所需要的时间, z_a 为路段 a 的分配交通量, c_a 为路段 a 能够达到的最大分配交通量, 即路段的通行能力, T_a 为路口时间延误值, Z_a 为路段 a 的需求交通量. 当 $Z_a < c_a$, 该路段处于畅通状态, $z_a = Z_a$. 当 $c_a < Z_a \leq 2c_a$ 时道路进入拥堵状态, 分配交通量 $z_a < Z_a$, 超负荷运行, 车速下降. 当路段上实际车流量 $Z_a > 2c_a$ 时, 路段上实际分配交通量 $z_a = 0$, 阻抗函数 $t_a \rightarrow \infty$.

道路拥堵时, 智能交通云控制系统实时寻优得到最短路径, 诱导用户按照最短路径行走, 在这里假设驾驶员根据路网的分配交通量选择交通阻抗最小的路径行驶. 将特定拥堵路段的 OD 交通量合理地分配到连接该 OD 点对的最短路径上, 每个路段得到交通流分配值 x_a .

本文采用容量限制增量分配法进行交通流分配, 其主要思想是将 OD 交通量分成若干份, 每次循环分配一份 OD 交通量到规定的最短路径上, 同时需更新各个路段的阻抗时间, 然后重新计算各个 OD 点对间的最短路径, 再进行下一份 OD 交通量分配.

容量限制增量分配算法步骤如下:

- 初始化, 将交通量 OD 矩阵进行适当分割, 分割次数为 N , 对任意的路段 a , 令 $k = 1, z_a^0 = 0$;
- 计算各路段阻抗: $t_a^k = t_a(z_a^{k-1})$;
- 用 Floyd 算法求出 OD 点对之间的最短路径, 用全有全无分配法将第 k 个 OD 交通流分割量分配到最短路径上, 累加各路段从该步分配得到的交通量, 累加量记为 w_a^k ;
- 计算各路段交通量: $z_a^k = z_a^{k-1} + w_a^k$;
- 判断, 如果 $k = N$, 则计算结束; 反之令 $k = k + 1$, 返回第 b) 步.

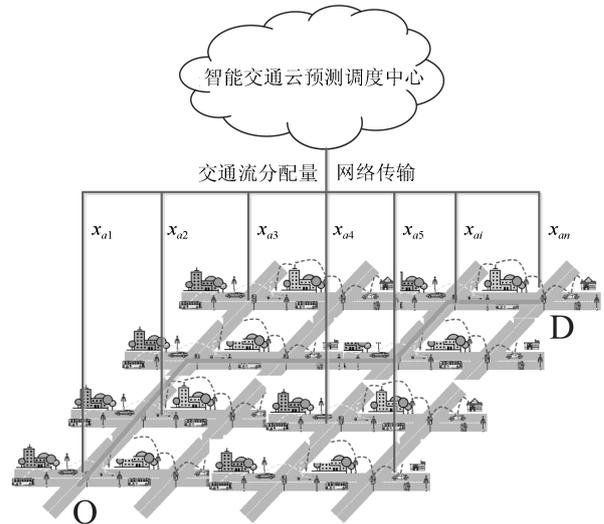


图 7 智能交通云控制系统预测调度示意图

Fig. 7 Schematic diagram of prediction scheduling for intelligent transportation cloud control systems

4 仿真实验

在智能交通信息物理融合云控制系统关键技术仿真实验中, 本地计算机选用 4 核 CPU、最高主频 2.9 GHz, 8 GB 内存的计算机. 云服务器选择租用成熟的商业云服务器: 北京三区、计算型 C2、4 核 CPU、8 GB 内存服务器, 该云端服务器配置与本地仿真实验计算机配置一致、带宽上限 100 Mbps、系统选用 Windows server 2012 R2 标准版 64 位中文版. 同时也可选用多台服务器、提供多任务多种类运行, 选用的云服务器台数越多, 费用越高. 购买的运营商服务器计算机类型最高配置可选为计算型 C2、32 核 CPU、120 GB 内存的计算服务器. 计算型 C2 是高计算性能和高并发读写应用的最佳选择. 对信息传输低时延和传输量要求较高时可选用高 I/O 型 I2 服务器. 该种服务器是高磁盘 I/O 的最佳选择, 提供每秒数万次低延迟性随机 I/O 操作 (IOPS), 包转发能力高达 30 万 pps, 可用于适合低时延 I/O 密集型应用.

在短时交通流预测仿真实验中, 我们采用美国加利福尼亚运输部的性能测试系统 (即 Caltrans PeMS 数据库) 数据来进行实验验证. 由于交通流数据具有很强的时间相关规律性, 非周末和周末数据差异性极强, 为了充分有效验证本文提出的方法, 我们选取十个不同的道路交通流检测点, Buena, Burbank, Commerce, Downey Glendale, La Mirada, Los Angeles, Norwalk, Santa Clarita 和 Santa Fe Springs. 从 2017 年 6 月 21 号起到 2017 年 7 月 12 号, 采用每周三的数据, 每个检测点共采集 4 组交通流数据. 每个检测点每天的数据样本数量为 288 个, 每个检测点总体的数据为 1 152 个, 整个数据集样本量共 11 520 个. 从 Caltrans PeMS 数据库中我们能够得到的交通流数据的最小采样时间间隔为 5 min, 本文中对采集的特定日期原始交通流数据进行处理, 形成以 5 min 为采样间隔的数据集作为智能预测模型的输入输出数据集, 来验证预测算法的有效性. 用前三组 6 月 21 号、6 月 28 号和 7 月 5 号的共 8 640 个交通流量的数据来对智能学习模型进行训练, 最后用训练好的智能学习模型来对 7 月 12 号的第四组 2 880 个数据进行预测验证.

4.1 基于 DBN-SVR 的短时交通流预测仿真

在云服务器和本地计算机 Matlab 2014a 环境中, DBN-SVR 网络模型的参数设置为: DBN 模型中的 RBM 网络层数为 3 层, 每一层的节点数分别为 4 个、4 个和 2 个, 对应的权值的训练迭代次数都取 10 次. 顶层预测模型 SVR 的核函数为 RBF 径向基函数, 核函数参数 g 是 16, 惩罚因子 c 为 11.3137. 然后对交通流测试数据集进行结果对比分析. 云服务器仿真结果如图 8 和图 9 所示. 本地运行平均时间为 8.5262 s, 在云端服务器的运行时间是 5.2758 s.

4.2 基于 BP-BELM 的短时交通流预测仿真

为了检验 BP-BELM 算法的性能, 本节通过对交通数据集进行训练和预测. 所有的测试结果使用 sigmoid 函数, 对交通流极限学习训练数据集的输入与输出数据进行 $[0, 1]$ 归一化处理, 云服务器仿真结果如图 10 和图 11 所示.

BP-BELM 短时交通流预测仿真实验在本地运行平均时间为 0.6268 s, 在云端服务器的运行时间是 0.3467 s. 云端服务器仿真实验运行时间明显降低, 数据计算能力明显强于本地.

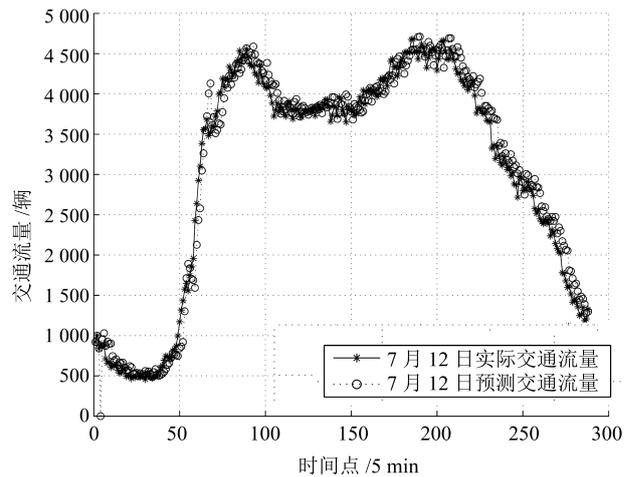


图 8 DBN-SVR 预测交通流与实际交通流的对比
Fig. 8 Comparison of DBN-SVR prediction traffic flow and actual traffic flow

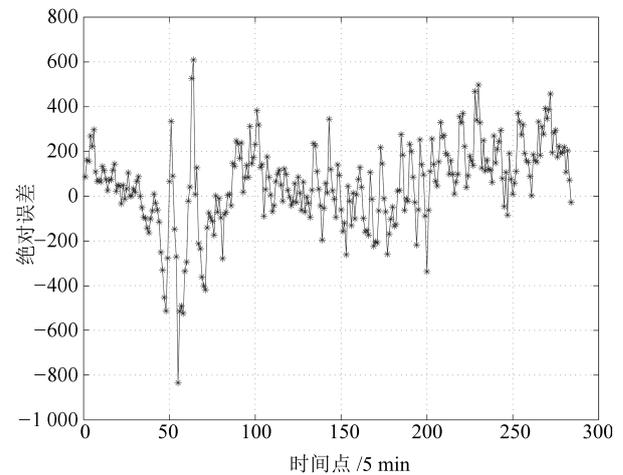


图 9 DBN-SVR 的预测误差
Fig. 9 Predicted error with DBN-SVR

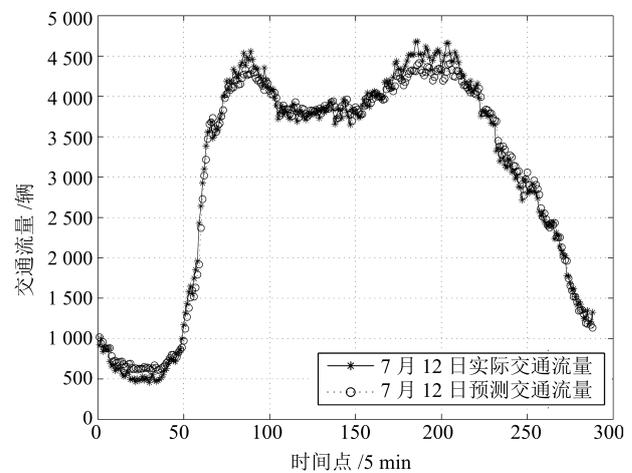


图 10 BP-BELM 预测交通流与实际交通流的对比
Fig. 10 Comparison of BP-BELM prediction traffic flow and actual traffic flow

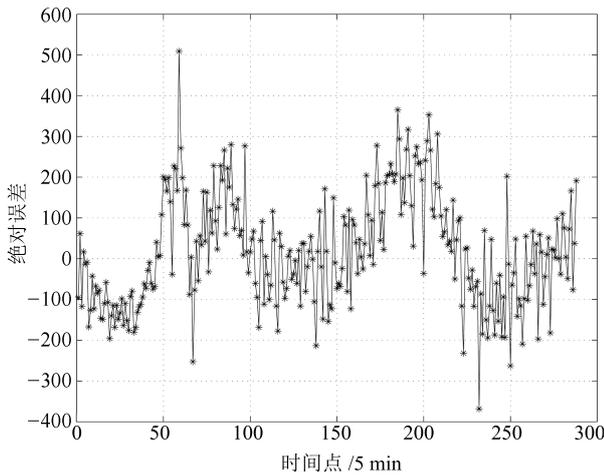


图 11 BP-BELM 的预测误差

Fig. 11 Predicted error with BP-BELM

4.3 预测误差分析及对比分析

对于本文研究的智能交通云控制信息物理融合系统中的短时交通流 DBN-SVR 模型和 BP-BELM 模型预测结果, 分别计算两种预测模型的均方误差和平均绝对百分比误差,

$$\text{MSE} = \frac{1}{N} \sqrt{\sum_{i=1}^N (y_i - \hat{y}_i)^2}$$

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\%$$

以上两式中, y_i 表示的是某一时刻的实际交通流值, \hat{y}_i 表示对应时刻的预测值. 对两种预测模型的性能进行分析比较并且与目前最新的交通流预测长短时记忆 (Long short-term memory, LSTM) 方法^[31] 进行对比分析, 结果如表 1 所示.

表 1 三种预测模型的性能比较
Table 1 Performance comparison of three prediction models

模型	MSE	MAPE (%)
DBN-SVR	0.05999	1.68051
BP-BELM	0.34084	10.7250
LSTM	0.37157	105.6117

根据图 9 和图 11 的对比, 可知 DBN-SVR 模型的智能交通流预测精确度较高, 方差后期波动范围较小. BP-BELM 模型前期预测准确度低, 前期的预测值与实际值的差距很大, 预测误差波动范围大. 对于大规模交通流数据, DBN-SVR 模型比 BP-BELM 模型有更优的预测效果.

本文选取对比的 LSTM 预测方法, 对于本实验的数据集效果较差, 平均百分比方差太大. 且由于短时交通流数据的采样频率高, 实验所用数据集中的数据个数多, 要求 LSTM 算法的输入节点个数为 846 个, 输出节点的个数为 288 个, 参数调节难度大, 云端计算时间为 512.1125 s.

另外在研究过程中, 对智能交通系统中的单个检测点的小样本交通流数据进行准确预测研究时, 我们同样得到了相关结果: DBN-SVR 模型对于单个节点小样本交通流数据进行预测时效果较差, 预测误差较大, 然而 BP-BELM 模型对单个节点小样本交通流数据进行预测准确度极高, 预测误差很小. 因此, 综合考虑智能交通云控制系统中的交通流预测研究, 对多个检测节点的大样本数据可采用 DBN-SVR 模型进行准确预测, 对精确的单个检测节点的小样本数据可采用 BP-BELM 模型进行准确预测, 两种智能机器学习算法并行使用, 互相协同配合, 保障智能交通云控制系统的良好运行.

4.4 智能交通流预测调度仿真

在智能交通云控制系统交通流预测调控仿真实验中, 在租用的云服务器上对预测交通流分配问题进行仿真验证. 数据采用城市道路交通模拟数据, 交通网络选取 83 个道路节点, 给定道路节点分布位置. 设置城市高速路容量 35 000 辆/小时, 城市快速路容量 25 000 辆/小时, 城市四车道容量 10 000 辆/小时, 城市二车道容量 6 500 辆/小时, 城市郊区三级公路容量 1 550 辆/小时.

图 12 中最窄宽度路段表示交通流量较少, 通行状况良好; 宽度增加路段表示交通流量增多, 通行状况一般; 较宽路段表示交通流量较大, 通行存在拥堵; 达到宽度上限路段表示交通流量饱和, 通行拥堵严重; 最宽路段表示交通流量严重超负荷, 不可通行.

另外, 交通网络连接路段线条的粗细代表车流量的多少. 由图可看出, 节点 13 到节点 31 的路段拥堵严重, 节点 52 到节点 57 路段交通流超出承受量, 不可通行.

接下来考虑预测的拥堵路段交通流量, 建立新的 OD 交通量分配矩阵, 利用容量限制增量分配法进行流量分配. 先将 OD 交通量进行 $N = 62$ 次分割, 然后利用 Floyd 算法求出任意两点间的最短路径, 最后逐点按照全有全无方法进行交通流分配. 智能交通云端交通流调度分配结果如图 13 所示. 从图中可看出节点 13 到节点 31 拥堵路段和节点 52 到节点 57 拥堵路段消失, 路网交通流得到了有效调度.

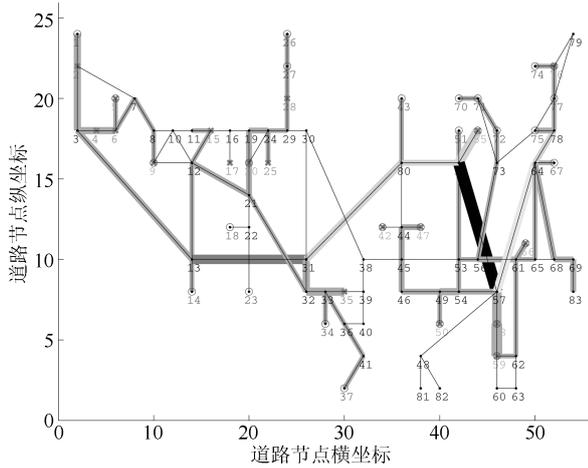


图 12 交通拥堵仿真结果

Fig. 12 Simulation result of traffic jams

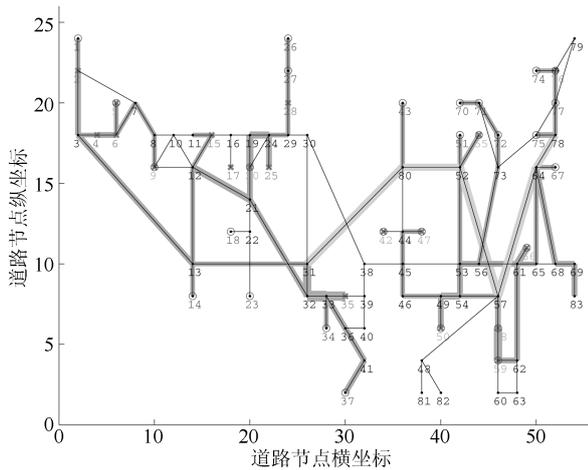


图 13 交通流增量分配后仿真结果

Fig. 13 Simulation result after incremental traffic flow assignment

5 结束语

本文对智能交通信息物理融合云控制系统的结构和核心技术进行了设计分析, 探讨了云控制在智能交通信息系统中的应用模式, 推广了云控制在智能交通领域的应用示范. 利用深度学习和超限学习预测算法, 对含有大量交通检测节点的整体路网交通流进行准确预测, 对交通拥堵状况进行预判. 利用交通流分配算法对交通流进行智能优化调度, 可改善各交通道路的运行拥堵状况. 另外, 智能学习算法和交通流调度策略在资源优化整合的智能交通云端运行, 避免了传统智能交通设备的计算存储局限性, 可预防设备故障, 并节约智能交通系统建设和维护成本. 事实上, 当前云控制技术还在发展阶段, 本文提出的智能交通信息物理融合云控制系统是云控制技术的初步应用, 如何对复杂交通数据在云端进行高效的分类处理, 得到最优的智能交通

实时云控制方案, 仍然是智能交通信息物理融合云控制系统研究需要解决的技术难点.

References

- 1 Wang Zhong-Jie, Xie Lu-Lu. Review on information physics fusion system. *Acta Automatica Sinica*, 2011, **37**(10): 1157–1166
(王中杰, 谢璐璐. 信息物理融合系统研究综述. 自动化学报, 2011, **37**(10): 1157–1166)
- 2 Xia Y. Cloud control systems. *IEEE/CAA Journal of Automatica Sinica*, 2015, **2**(2): 134–142
- 3 Xia Yuan-Qing. Cloud control systems and its challenges. *Acta Automatica Sinica*, 2016, **42**(1): 1–12
(夏元清. 云控制系统及其面临的挑战. 自动化学报, 2016, **42**(1): 1–12)
- 4 Xia Y. From networked control systems to cloud control systems. In: Proceedings of the 31st Chinese Control Conference (CCC). Hefei, China, 2012. 5878–5883
- 5 Ma Qing-Lu, Si Hai-Lin, Guo Jian-Wei. Cloud control strategy for urban traffic area linkage under the environment of Internet of things. *Application Research of Computers*, 2013, **30**(9): 2711–2714
(马庆禄, 斯海林, 郭建伟. 物联网环境下城市交通区域联动的云控制策略. 计算机应用研究, 2013, **30**(9): 2711–2714)
- 6 Wang F Y, Zheng N N, Cao D, Martinez C M, Li L, Liu T. Parallel driving in CPSS: a unified approach for transport automation and vehicle intelligence. *IEEE/CAA Journal of Automatica Sinica*, 2017, **4**(4): 577–587
- 7 Chan K Y, Dillon T S, Singh J, Chang E. Neural-network-based models for short-term traffic flow forecasting using a hybrid exponential smoothing and Levenberg-Marquardt algorithm. *IEEE Transactions on Intelligent Transportation Systems*, 2012, **13**(2): 644–654
- 8 Meng D, Jia Y. Finite-time consensus for multi-agent systems via terminal feedback iterative learning. *IET Control Theory & Applications*, 2011, **5**(8): 2098–2110
- 9 Nascimento J C, Silva J G, Marques J S, Lemos J M. Manifold learning for object tracking with multiple nonlinear models. *IEEE Transactions on Image Processing*, 2014, **23**(4): 1593–1604
- 10 Xue J, Shi Z. Short-time traffic flow prediction based on chaos time series theory. *Journal of Transportation Systems Engineering and Information Technology*, 2014, **8**(5): 68–72
- 11 Polson N G, Sokolov V O. Deep learning for short-term traffic flow prediction. *Transportation Research Part C Emerging Technologies*, 2017, **79**, 1–17
- 12 Kumar S V. Traffic flow prediction using Kalman filtering technique. *Procedia Engineering*, 2017, **187**, 582–587
- 13 Luo Xiang-Long, Jiao Qin-Qin, Niu Li-Yao, Sun Zhuang-Wen. Short term traffic flow prediction based on deep learning. *Application Research of Computers*, 2017, **34**(1): 91–93
(罗向龙, 焦琴琴, 牛力瑶, 孙壮文. 基于深度学习的短时交通流预测. 计算机应用研究, 2017, **34**(1): 91–93)
- 14 Xu Y, Kong Q, Klette R, Liu Y. Accurate and interpretable bayesian MARS for traffic flow prediction. *IEEE Transactions on Intelligent Transportation Systems*, 2014, **15**(6): 2457–2469
- 15 Oh S, Kim Y, Hong J. Urban traffic flow prediction system using a multifactor pattern recognition model. *IEEE Transactions on Intelligent Transportation Systems*, 2015, **16**(5): 2744–2755

- 16 Moretti F, Pizzuti S, Panziera S, Annunziato M, Urban traffic flow forecasting through statistical and neural network bagging ensemble hybrid modeling. *Neurocomputing*, 2015, **167**(C): 3–7
- 17 Jeong Y S, Byon Y J, Castro-Neto M M, Easa S M, Supervised weighting-online learning algorithm for short-term traffic flow prediction. *IEEE Transactions on Intelligent Transportation Systems*, 2013, **14**(4): 1700–1707
- 18 Chan K Y, Dillion T S. On-road sensor configuration design for traffic flow prediction using fuzzy neural networks and taguchi method. *IEEE Transactions on Instrumentation and Measurement*, 2013, **62**(1): 50–59
- 19 Man Rui-Jun, Liang Xue-Chun. Traffic flow forecasting based on multi-scale wavelet support vector machine. *Computer Simulation*, 2013, **30**(11): 156–159
(满瑞君, 梁雪春. 基于多尺度小波支持向量机的交通流预测. 计算机仿真, 2013, **30**(11): 156–159)
- 20 Huang W H, Song G J, Hong H K, Xie K. Deep architecture for traffic flow prediction: deep belief networks with multitask learning. *IEEE Transactions on Intelligent Transportation Systems*, 2014, **15**(5): 2191–2201
- 21 Koesdwiady A, Souza R, Karray F. Improving traffic flow prediction with weather information in connected cars: a deep learning approach. *IEEE Transactions on Vehicular Technology*, 2016, **65**(12): 9508–9517
- 22 Hinton G, Osindero S, Teh Y. A fast learning algorithm for deep belief nets. *Neurocomputing*, 2006, **18**(7): 1527–1554
- 23 Kuremoto T, Kimura S, Kobayashi K, Obayashi M. Time series forecasting using a deep belief network with restricted Boltzmann machines. *Neurocomputing*, 2014, **137**(15): 47–56
- 24 Tan Juan, Wang Sheng-Chun. Traffic congestion prediction model based on deep learning. *Application Research of Computers*, 2015, **32**(10): 2951–2954
(谭娟, 王胜春. 基于深度学习的交通拥堵预测模型研究. 计算机应用研究, 2015, **32**(10): 2951–2954)
- 25 Lv Y, Duan Y, Wang W, Li Z, Wang F, Traffic flow prediction with big data: a deep learning approach. *IEEE Transactions on Intelligent Transportation Systems*, 2015, **16**(2): 865–873
- 26 Huang G B, Chen L, Siew C K. Universal approximation using incremental constructive feedforward networks with random hidden nodes. *IEEE Transactions on Neural Networks*, 2006, **17**(4): 879–892
- 27 Huang G B, Zhou H, Ding X, Zhang R. Extreme learning machine for regression and multiclass classification. *IEEE Transactions on Systems Man and Cybernetics*, 2012, **42**(2): 513–529
- 28 Huang W H, Song G J, Hong H K, Xie K. Deep architecture for traffic flow prediction: deep belief networks with multitask learning. *IEEE Transactions on Intelligent Transportation Systems*, 2014, **15**(5): 2191–2201
- 29 Xia Y, Qin Y, Zhai D H, Chai S. Further results on cloud control systems. *Science China Information Sciences*, 2016, **59**(7): 073201
- 30 Xia Yuan-Qing, Mahmoud M S, Li Hui-Fang, Zhang Jin-Hui. Interaction between control and computation theory: cloud control. *Journal of Command and Control*, 2017, **3**(2): 99–118
(夏元清, Mahmoud M S, 李慧芳, 张金会. 控制与计算理论的交互: 云控制. 指挥与控制学报, 2017, **3**(2): 99–118)
- 31 Kang D, Lv Y, Chen Y. Short-term traffic flow prediction with LSTM recurrent neural network. In: Proceedings of the 2017 IEEE 20th International Conference on Intelligent Transportation Systems. Yokohama, Japan: IEEE, 2017. 1–6

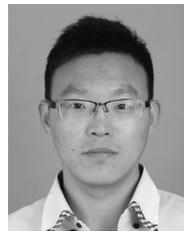


夏元清 北京理工大学自动化学院教授. 主要研究方向为云控制, 云数据中心优化调度管理, 智能交通, 模型预测控制, 自抗扰控制, 飞行器控制和空天地一体化网络协同控制. 本文通信作者.

E-mail: xia.yuanqing@bit.edu.cn

(**XIA Yuan-Qing** Professor at the School of Automation, Beijing Institute

of Technology. His research interest covers cloud control, cloud data center optimization scheduling and management, intelligent transportation, model predictive control, active disturbance rejection control, flight control and networked cooperative control for integration of space, air and earth. Corresponding author of this paper.)



闫策 北京理工大学自动化学院博士研究生. 主要研究方向为云控制, 云 workflow 最优化调度, 智能交通, 执行器饱和控制, Delta 算子, 有限频域.

E-mail: yancemc@163.com

(**YAN Ce** Ph.D. candidate at Beijing Institute of Technology. His research interest covers cloud control,

cloud workflow optimization scheduling, intelligent transportation, actuator saturation, delta operator and finite frequency.)



王笑京 交通运输部公路科学研究院总工程师, 研究员. 主要研究方向为智能交通系统, 交通信息与控制工程科学与技术. E-mail: xj.wang@rioh.cn

(**WANG Xiao-Jing** Research fellow and chief engineer at Research Institute of Highway Ministry of Transport. His research interest covers intelligent transportation system, science and technology of

traffic information and control engineering.)



宋向辉 交通运输部公路科学研究院研究员. 主要研究方向为智能交通系统, 交通信息与控制工程科学与技术.

E-mail: sxh@itsc.cn

(**SONG Xiang-Hui** Research fellow at Research Institute of Highway Ministry of Transport. Her research interest covers intelligent transportation system, science and technology of traffic information and control engineering.)

system, science and technology of traffic information and control engineering.)