

行程时间预测方法研究*

柏梦婷¹, 林杨欣¹, 马萌², 王平^{1,2,3}

¹(北京大学 软件与微电子学院, 北京 102600)

²(软件工程国家工程研究中心(北京大学), 北京 100871)

³(高可信软件技术教育部重点实验室(北京大学), 北京 100871)

通讯作者: 马萌, E-mail: mameng@pku.edu.cn; 王平, E-mail: pwang@pku.edu.cn



摘要: 行程时间预测, 有助于实施高级旅行者信息系统。自 20 世纪 90 年代起, 已经有多种行程时间预测方法被研发出来。将行程时间预测方法分为模型驱动方法和数据驱动方法两大类。介绍了两种常见的模型驱动方法, 即排队论模型和细胞传输模型。数据驱动方法被分类为参数方法和非参数方法: 参数方法包括线性回归、自回归集成移动平均和卡尔曼滤波, 非参数方法包括神经网络、支持向量回归、最近邻和集成学习方法。对现有行程时间预测方法从源数据、预测范围、准确率、优缺点和适用范围等方面进行了分析总结。针对现有方法的一些缺点, 提出了可能的解决方案。给出了一种新颖的数据预处理框架和一个行程时间预测模型, 最后指出了未来的研究方向。

关键词: 行程时间预测; 模型驱动; 数据驱动; 参数方法; 非参数方法

中图法分类号: TP391

中文引用格式: 柏梦婷, 林杨欣, 马萌, 王平. 行程时间预测方法研究. 软件学报, 2020, 31(12): 3753-3771. <http://www.jos.org.cn/1000-9825/5875.htm>

英文引用格式: Bai MT, Lin YX, Ma M, Wang P. Survey of traffic travel-time prediction methods. Ruan Jian Xue Bao/Journal of Software, 2020, 31(12): 3753-3771 (in Chinese). <http://www.jos.org.cn/1000-9825/5875.htm>

Survey of Traffic Travel-time Prediction Methods

BAI Meng-Ting¹, LIN Yang-Xin¹, MA Meng², WANG Ping^{1,2,3}

¹(School of Software and Microelectronics, Peking University, Beijing 102600, China)

²(National Engineering Research Center for Software Engineering (Peking University), Beijing 100871, China)

³(Key Laboratory of High Confidence Software Technologies of Ministry of Education (Peking University), Beijing 100871, China)

Abstract: Travel-time prediction can help implement advanced traveler information systems. In recent years, a variety of travel-time prediction methods have been developed. In this study, travel-time prediction methods are classified into two categories: model-driven and data-driven methods. Two common model-driven approaches are elaborated, namely queuing theory and cell transmission model. The data-driven methods are classified into parametric and non-parametric methods. Parametric methods include linear regression, autoregressive integrated moving average, and Kalman filtering. Non-parametric methods contain neural networks, support vector regression, nearest neighbors, and ensemble learning methods. Existing travel-time prediction methods are analyzed and concluded from source data, prediction range, accuracy, advantages, disadvantages, and application scenarios. Several solutions are proposed for some shortcomings of existing methods. A novel data preprocessing framework and a travel-time prediction model are presented, and future research challenges are highlighted.

Key words: travel-time prediction; model-driven; data-driven; parametric methods; non-parametric methods

* 基金项目: 国家重点研发计划(2017YFB1200700); 国家自然科学基金(61701007)

Foundation item: National Key Research and Development Program of China (2017YFB1200700); National Natural Science Foundation of China (61701007)

收稿时间: 2018-11-03; 修改时间: 2019-05-08; 采用时间: 2019-07-10

在日常出行中,行程时间是用户最重视的交通信息之一.行程时间预测可以为动态路径导航^[1]、道路拥堵控制^[2]、最优调度^[3]和交通事故检测^[4]等应用提供有用的信息.

行程时间预测是智能交通系统(intelligent transportation systems,简称 ITS)^[5]实施过程中必不可少的环节,尤其对高级旅行者信息系统(advanced traveler information systems,简称 ATIS)^[6]至关重要.ATIS 是 ITS 中的一个关键组成部分,它旨在使用一系列技术(如无线、电视、电话、互联网和车载动态导航系统等)来满足旅客的信息需求,帮助他们做出更明智的出行决策,缓解交通拥堵造成的影响^[7].它能够为旅客提供目的地、路线、出发时间等信息,这些实时信息也能帮助重新规划路线来避免意外的交通拥堵^[8].因此,研究行程时间预测具有重要现实意义.

行程时间预测是一项复杂且具有挑战性的任务.由于天气、路网交通状况等因素的影响,行程时间通常在不同时期和不同交通状况下出现强烈的波动^[9].为了准确预测行程时间,通常需要上、下游道路的数据.因为在拥堵交通状况下,上、下游车辆会对目标道路的行程时间造成严重影响.因此,行程时间预测需要高度复杂的交通模型,或能从数据中挖掘交通模式的数据驱动模型.

本文的 4 个主要贡献是:

- 将自 1991 年以来近 50 篇相关文献中提到的行程时间预测方法进行分类和比较;
- 将模型驱动和数据驱动方法进行了详细分类,从数据、预测范围、准确率、优缺点和适用范围等方面进行了对比,并对文中提到的主要改进方法进行了分析;
- 指出了现有行程时间预测方法的一些缺点和可能的解决方案,明确了未来研究方向;
- 提出了一种新的数据处理框架和一种新行程时间预测方法.

本文第 1 节对交通行程时间预测问题进行定义,并给出行程时间预测的通用预测框架.第 2 节对已有的行程时间预测方法进行总结和分类.第 3 节对现有的行程时间预测方法进行归类和分析,并从预测范围、优缺点和适用范围等方面进行概括.第 4 节对行程时间预测过程中存在的一些问题和未来研究方向进行分析和总结,提出一些现有方法的缺点的可能解决方案,也对拟议的数据处理框架和新的行程时间预测方法加以介绍.第 5 节对行程时间预测方法分类进行分析总结.

1 行程时间预测问题

1.1 行程时间预测定义

行程时间预测是指预测未来一段时间内,通过指定路段或者从起始地到目的地所花费的时间^[10].行程时间预测一般有直接预测和间接预测两种方法.

- 直接预测方法^[11]通常利用历史测量的行程时间序列数据 $\{x_1, x_2, \dots, x_{t-1}, x_t\}$,使用参数或者非参数方法拟合行程时间序列数据的函数关系,对未来一段时间 $\{t+1, t+2, \dots\}$ 的行程时间 $\{x_{t+1}, x_{t+2}, \dots\}$ 进行预测;
- 间接预测方法是指根据历史测量的流量、密度、占用率或平均速度等数据,通过建立交通流模型来预测未来的时空速度,然后再预测未来的行程时间^[11].

1.2 行程时间预测框架

行程时间预测问题分为数据收集、数据处理和行程时间预测这 3 个模块,预测框架如图 1 所示.

- 数据收集模块将感应环路检测器、全球定位系统等多种设备收集的交通数据存储于交通数据库中;
- 数据处理模块对原始交通数据进行异常处理、数据聚合等操作,然后导入历史数据库;
- 行程时间预测模块接收来自历史数据库中的历史数据和各种设备收集到的实时数据,通过一些预测算法直接或间接对未来一段时间的行程时间进行预测.

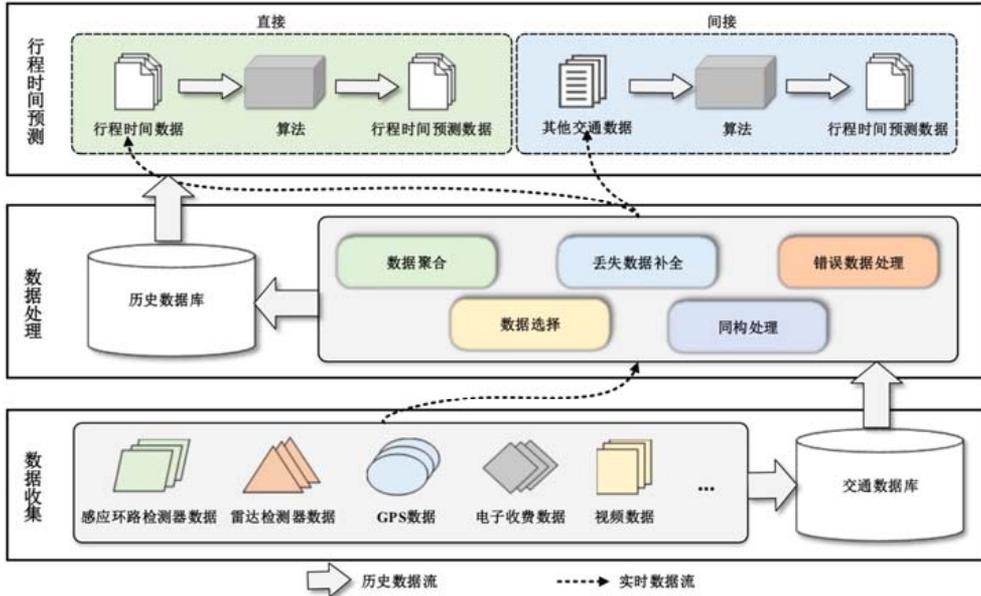


Fig.1 Framework of travel-time prediction

图 1 行程时间预测框架

2 行程时间预测方法分类

自 1991 年起,研究者们已经提出一系列的行程时间预测方法,特别是应用于高速公路上的行程时间预测方法^[12,13].本文将行程时间预测方法分类为模型驱动方法和数据驱动方法,如图 2 所示.

- 模型驱动方法一般有确定的交通模型,通过对交通参数(如流量、密度和占用率等)进行建模来预测未来行程时间.模型驱动方法考虑单个车辆的运动特征^[14]或整体车流运动特征^[15].Oh 等人^[16]回顾了基于模型的行程时间预测方法,并将它们按照模型细节分为宏观、微观、介观和细胞自动机等 4 类,并从预测范围、准确性、效率、适用性和稳健性方面进行了分析.然而该文献^[16]主要回顾的是基于模型的预测框架,其框架的核心方法大多是排队论模型^[17]和细胞传输模型^[18]或者其变体,而对这两种核心方法并没有做详细的介绍和分析.因此,本文不再对模型驱动方法进行详细分类,而仅介绍排队论模型^[17]和细胞传输模型^[18]这两种常见模型;
- 数据驱动方法将交通状况与当前数据和历史数据相结合,从数据中挖掘交通模式,从而对未来的行程时间进行预测.已有许多研究对数据驱动方法进行分类:Chrobok 等人^[19]分类为参数回归、非参数回归和神经网络;Hinsbergen 等人^[20]分类为朴素模型、参数模型和非参数模型;Yu^[21],Fei^[22]和 Oh 等人^[23]分类为参数模型和非参数模型.Oh 等人^[23]对高速公路上的短期行程时间预测的数据驱动方法进行了分类,介绍了线性回归^[24]、自回归移动平均^[25]、卡尔曼滤波^[26]、神经网络^[27]和最近邻^[28]等 5 类方法.该文献仅关注应用在高速公路上的数据驱动方法,分类较少.此外,近几年有一些新的行程时间预测的数据驱动方法值得关注:Bai 等人^[29]对行程时间预测的方法进行了较为详细的分类,也介绍了近几年提出的一些新方法,但是方法的对比粒度不够详细,而且文中提及的方法较少,没有对一些主要改进方法进行原因分析.

本文是在我们之前的工作^[29]基础上全面扩展而来的,对现有的行程时间预测方法进行了更全面、分类粒度更细并且涵盖更多新方法的总结分析.本文将数据驱动方法分为参数和非参数方法.

- 参数方法是指假定总体服从某一分布,并按照预设的规则训练模型的方法.常见的参数方法包括线性回归^[24]、自回归集成移动平均^[25]和卡尔曼滤波^[26]等;

- 非参数方法对总体的分布不做任何假设,直接或间接按照给定数据进行训练.常见的非参数方法包括神经网络(反向传播网络^[27]、循环神经网络^[30]、长短期记忆网络^[31]和状态空间网络^[32])、支持向量回归^[33,34]、最近邻^[28]和集成学习方法^[9]等.

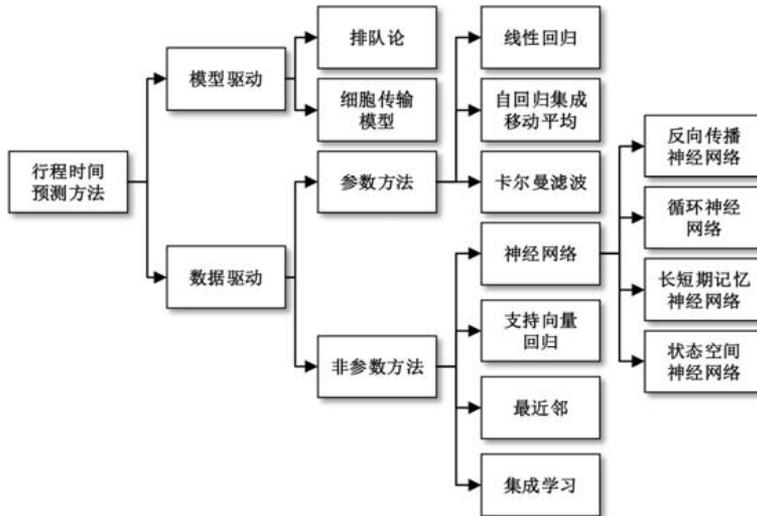


Fig.2 Classification of travel-time prediction methods

图2 行程时间预测方法分类

3 行程时间预测方法研究现状

3.1 模型驱动方法

模型驱动方法通过对交通流特征进行建模,来描述整体车流的运动特征或个体车辆的运动规律.20世纪90年代以来,已有许多交通流模型被用于行程时间预测^[35,36].本文主要介绍排队论方法和细胞传输模型.

(1) 排队论

排队论模型一般会考虑交叉路口信号灯对车辆的运动影响,对路口等待队列的形成和消散过程中的交通参数进行统计分析,然后预测行程时间.

Takaba 等人^[17]使用基于排队论的沙漏模型和延时模型预测行程时间.沙漏模型将自由流速行程时间和拥塞行程时间之和作为最终预测的行程时间.而延时模型将自由流速行程时间和延迟时间之和作为预测结果.实验结果表明:在非拥塞状况下,两种模型的错误率不超过24%.由于延时模型估计的延迟时间在交通拥堵时误差会增大,模型性能会降低,因此,沙漏模型比延时模型的性能更稳定.Skabardonis 等人^[37]将行程时间视为自由行驶时间与交通信号延迟时间之和,使用基于运动波理论的排队论模型进行了预测.实验结果表明:在一个信号灯周期内,预测行程时间与实际行程时间差异不超过5%.Akiva 等人^[38]提出了 DynaMIT 框架来预测交通状况.假设预测时刻和当前时刻的交通状况类似,则预测结果是当前行程时间和过去行程时间的线性组合.由于该框架使用过去一段时间的交通状况和当前时刻的实时数据对未来的交通状况进行预测,当未来交通状况发生变化时,该模型的性能会降低.因此,这种方法只适用于交通状况未明显变化的情况,不适合长期预测.

(2) 细胞传输模型

1992年,Daganzo 等人^[18]提出了细胞传输模型(cell transmission model,简称CTM).CTM基于流体力学理论,能根据选择的中间点描述和预测交通流.之后,CTM被推广到交通网络^[39],并应用于高速公路和专用车道的研究^[40]以及交通仿真^[41].CTM的主要思想是:将道路划分为等长单元即“细胞”,同时,将时间离散化为等长的时间间隔.细胞的长度等于车辆以自由流速在一个时间间隔内行驶的距离.车辆沿行驶方向从一个细胞驶入相邻的另一个细胞.CTM对于流量和密度之间的关系进行了分段线性化处理.当交通不拥堵时,上一个细胞的车辆数

限制了流量;当交通拥堵时,下一个细胞的空间可用量限制了流量.

表 1 列出了一些模型驱动的行程时间预测方法的源数据、预测范围、准确率、优缺点和适用范围等信息.

Table 1 Model-driven methods

表 1 模型驱动方法

作者	方法	源数据	预测范围	准确率	优点	缺点	适用范围
Takaba 等人 ^[17]	排队论 (沙漏模型, 延时模型)	Mejiro 大街 (4.4km): 等待队列长度, 流量, 行程时间	5min	ER: 5%~18%	沙漏模型性能比较稳定; 方法简单	延时模型在拥堵时性能降低, 不够稳定; 需要估计多种交通参数	道路畅通不拥堵的情况; 城区交叉路口
Akiva 等人 ^[38]	排队论 (DynaMIT)	波士顿公路: 等待队列长度, 行程时间			能捕获近期交通状态; 可以连续进行预测	交通状况明显变化时性能降低	交通状况未明显变化的情况; 城区短期预测
Skabardonis 等人 ^[37]	排队论	M 大街, 林肯大道: 流量, 占用率, 信号灯周期	7min	ER: <5%	不依赖站点特定参数或短期流量预测; 易于转移	需要提供每个信号灯周期等参数	信号灯周期固定的城区干道
Tampere 等人 ^[42]	CTM, 卡尔曼滤波	高速公路 (15km): 流量, 占用率, 速度	15min, 30min		在线模型; 可用于非线性状态空间	卡尔曼过滤器更新频率不够高	高速公路在线预测
Juri 等人 ^[43]	CTM, 统计方法	高速公路 仿真实验数据		ER: <15%	框架灵活; 在线预测	长期预测性能下降	高速公路在线短期预测
Wan 等人 ^[45]	LN-CTM, 聚类	高速公路 (3.4km): 行程时间			提供行程时间概率分布	假设数据符合高斯分布且相互不相关; 对参数调整敏感; 计算量随着数据量线性增加	高速公路和主干道
Xiong 等人 ^[44]	CTM, 自回归移动平均	M4 高速公路: 速度, 流量	5min		可以预测短期流量; 能够预测交通网络拥塞	根据特定地点的历史数据训练模型; 无法处理有信号灯的 交通状况	高速公路短期预测
Seybold 等人 ^[46]	CTM, 最小二乘, 整体最小二乘	E4 高速公路 (7.4km): 速度, 流量		MPE: 19%	整体最小二乘法提高了模型性能	需要更长的模型参数校准时间	高速公路

注: ER: 错误率; MPE: 平均百分比误差

Tampere 等人^[42]提出了扩展卡尔曼过滤器-细胞传输模型(EKF-CTM),这种模型使用卡尔曼过滤器来估计当前的交通状况,并根据交通状况将 CTM 模型在线性和非线性之间进行转换来预测交通状况.高速公路仿真结果表明,该模型能捕获拥塞并预测短期行程时间.Juri 等人^[43]使用点到点的在线短期预测方法,将统计预测技术与 CTM 交通仿真相结合,使用滑动窗口框架进行在线行程时间预测.Xiong 等人^[44]建立了一个三级结构的 CTM 模型,使用自回归集成移动平均方法进行高速公路的短期流量预测,根据预测流量和 N 曲线分析预测短期行程时间.Wan 等人^[45]使用基于随机模型的链路节点细胞传输模型(link-node cell transmission model,简称 LN-CTM)来对流量建模,并提供行程时间的概率分布.该模型将行程时间分布表示为高斯混合模型,并使用期望最大化方法进行数据聚类.仿真实验结果表明,该方法能准确生成行程时间的多模态分布.然而,该方法每次仿真生成一个行程时间样本,在给定行程时间概率分布的置信度的情况下,计算量和执行时间随着样本量的增加而线性增加.Seybold 等人^[46]提出了一种改进的 CTM 模型——CTM-u 模型来预测行程时间.该方法使用最小二乘法和整体最小二乘拟合校准模型参数,两者的区别在于误差项不同.实验结果表明:当最大密度参数固定时,仅使用最

小二乘法校准参数的模型的平均百分比误差约为 35%,而使用整体最小二乘拟合对参数进行校准的模型的平均百分比误差减少到了 19%。我们认为,CTM-u 模型性能提升是由于参数的校准,最小二乘法在流量或者速度单一维度上进行参数校准,而整体最小二乘法则保证了两个维度上参数的准确性。

3.2 数据驱动方法

数据驱动方法的主要思想是:在模型不确定的情况下,使用大量历史数据进行学习和调优,最后,模型能够达到近似真实情况的效果。数据驱动方法一般分为参数方法和非参数方法,参数方法和非参数方法的主要区别在于是否假定总体服从某一分布。表 2 从源数据、预测范围、准确率、优缺点和适用范围等方面对一些数据驱动方法进行了对比。

Table 2 Data-driven methods

表 2 数据驱动方法

作者	方法	源数据	预测范围	准确率	优点	缺点	适用范围
Kwon 等人 ^[24]	LR	I-880N & S 高速路(10km): 行程时间, 流量, 占用率	5 min~60min	MAPE: 7.7%~23%	参数少; 模型简单; 描述线性关系	准确率较低; 不能解决非线性问题	高速公路 短期预测
Zhang 等人 ^[47]	LR (时变系数)	I-880N 高速路 (6km):行程时间, 速度;I-405 高速路(32km): 流量, 占用率	I-880: 0~60min I-405: 0~90min	I-880 MAPE: 7%~24% I-405 MAPE: 8%~14%	易于实施; 计算效率高	需要预先 存储不同 时间的 模型参数	高速公路 长期预测
Rice 等人 ^[48]	LR (时变系数)	I-10E 高速路 (77km):流量, 占用率	60min	RMSE: <10min	易于实施; 计算效率高; 在线预测	参数需要 离线计算, 比较耗时	高速公路 长期预测
Sun 等人 ^[49]	多变量 局部 LR	US-290 高速路 (2.5km):速度	25min	MRE: 11.38%	模型简单; 短期预测 效果较好	需要权衡 性能和 计算复杂度	高速公路 短期预测
Oda 等人 ^[50]	ARIMA	国道 16 号高速 公路(7km): 流量, 占用率	5min	ME: <13.9%	参数少; 计算高效	性能受参数 (车辆长度) 影响较大	高速公路 短期预测
Xia 等人 ^[56]	SARIMA, KF	I-80 高速公路 (14.5km): 流量, 占用率	5min	MAPE: 5.34%	在线预测; 能捕获 交通动态	在交通拥堵和 发生事故时 性能降低	高速公路; 在线预测
Sun 等人 ^[57]	SARIMA, KF	深圳罗湖 和福田区: GPS 数据	5min	MAE:4.88% MAPE:6.38% RMSE:20.34%	适应实时 交通状况	模型预测 结果波动 较大	城区 道路网络
Chen 等人 ^[62]	KF	I-80 高速公路: 行程时间	5min~2h	MARE:<2.1% RRSE:<2.8% MRE:<5.5%	使用 实时数据	长期预测性能 降低;性能受 车辆采样率 影响较大	高速公路 预测
Ji 等人 ^[61]	KF, 参数回归	上海海宁路, 鸭绿江路 周家嘴路: 行程时间	15min	MRE:1.6‰ MARE:2.13‰	结合相邻 道路的数据	需要对数据 平滑处理; 无法承受 高频更新	城市 主干道; 短期预测
Ojedra 等人 ^[63]	KF, CTM	高速公路 仿真(10.5km): 速度, 流量	45min	错误率:<9%	在线预测; 无需大型 数据库; 参数较少	受交通拥堵 影响较大; 较长期预测 性能下降	高速公路; 在线 短期预测
Liu 等人 ^[64]	SES, KF	高速路 (17.7km): 行程时间	5min	MARE:3.1%	性能稳定; 能捕获动态 交通模式	模型对参数 调节敏感	高速公路; 短期预测
Park 等人 ^[71]	单隐层 BPNN	US-290 高速 公路(27.6km): 行程时间	5 min~25min	MAPE: 7.4%~17.9%	考虑了相邻 道路间的 相关性对 模型的影响	需要经验 或实验来 确定参数; 不考虑实际 交通状况	高速公路

Table 2 Data-driven methods (Continued)

表 2 数据驱动方法(续)

作者	方法	源数据	预测范围	准确率	优点	缺点	适用范围
Chen 等人 ^[72]	单隐层 BPNN	北京三环高速公路:速度	2min~1h	MRE:<10%	迭代预测; SDTCM 准确率高, SITCM 平稳性好	无法动态训练模型;需要在模型准确性和训练时间间权衡	高速公路
Wisitpongphan 等人 ^[10]	三隐层 BPNN	Hwy35 高速路 (22km):速度, 行程时间,GPS	3h	MSE:<3%	准确率高; 滑动窗口滚动预测	要根据交通状况训练多个模型	高速公路
Yun 等人 ^[73]	BPNN, FIR, RNN	州际、城际高速公路和城市交叉路口:行程时间		BPNN: MAPE:<17.3% MARE<12.3% FIR: MAPE:<8.2% MARE<7.1% RNN: MAPE:<5.4% MARE:<5.2%	FIR 对于周期性数据预测性能更好; RNN 对于随机数据性能更好	需要对数据进行预处理;无法处理意外事故和天气突变等异常情况	高速公路; 城市道路网络 (交叉口)
Abdulhai 等人 ^[75]	RNN (TDRN), GA	I-5 高速公路仿真(8km):流量,密度	30s~15min	MPE:<15%	动态自适应; 结合相邻道路数据	预测区间和数据聚合水平不一致时性能降低	高速公路短期预测
Dia 等人 ^[76]	RNN (TDRN)	澳大利亚高速路(1.5km):行程时间, 流量,速度	20s~15min	MPE:<7%	考虑当前道路上下游的数据	需要进行多次实验确定最佳网络结构	高速公路短期预测
Duan 等人 ^[77]	LSTM	英国高速公路:行程时间	15min~60min	MRE: 0.17~0.77	能提取时间序列潜在模式	不同道路的最佳网络结构不同	高速公路
Liu 等人 ^[79]	LSTM-DNN	I-80 高速公路:行程时间	5min~60min	MAPE: 1%~7.3%	滑动窗口滚动预测; 准确率高	需确定网络参数;训练时间长	高速公路; 长期预测
Lint 等人 ^[32]	SSNN	A13 高速公路仿真(7.3km):行程时间, 速度,流量		MRE:<10%	结合了时间和空间信息;网络结构较灵活	收敛速度慢; 训练时间长	高速公路
Lint 等人 ^[80]	SSNN, 指数平滑	A13 高速公路仿真(8.5km):速度,行程时间	1min	MRE:1.6%	结合时间和空间信息;鲁棒性强	权重初始化要适当;地点特定	高速公路
Li 等人 ^[81]	BSSNN, 贝叶斯	深圳市滨河路(8km):行程时间	2min	MAPE: 7.34%	稳定性强; 加快收敛	性能受置信区间参数影响大	城区主干道
Wu 等人 ^[83]	SVR	台湾地区高速路(45,161, 350km):速度	3min	MRE:<4.5% RMSE:<7.4%	适用于交通数据分析; 收敛速度快; 参数较少	性能受数据质量影响较大; 对核函数敏感	高速公路短期长距离预测
Castro-Neto 等人 ^[84]	OL-SVR	加利福尼亚州高速路:行程时间	5min	非拥堵 MAPE:<9% 拥堵 MAPE:<23.4%	在线预测和更新模型; 及时捕获交通变化	只适合短期预测;性能依赖于实时数据	高速公路短期预测
Gao 等人 ^[85]	SVR, IGA	廊坊市和平路数据:行程时间	5min	MRE:9.7% MAPE:12.4%	通过 IGA 选择模型参数;使用验证集避免过拟合	对核函数和参数选择敏感;具有滞后效应	城区主干道短期预测
Bajwa 等人 ^[88]	k-NN	东京高速公路(283.3km):行程时间	5min	RMSE: <12.5%	模型简单,无需训练;鲁棒性较好;根据交通状况自适应调整参数;可转移性强	交通拥堵和突变时性能降低;计算复杂度高;性能依赖于数据库的质量	高速公路短期预测

Table 2 Data-driven methods (Continued)

表 2 数据驱动方法(续)

作者	方法	源数据	预测范围	准确率	优点	缺点	适用范围
Lim 等人 ^[89]	k -NN	京釜高速公路 (3.4km): 行程时间	5min~30min	MAPE: 4.3%~14.8%	能获取交通状态的 时间变化和空间 变化;参数少	计算量大; 性能依赖于 数据库的质量	高速公路 短期预测
Wang 等人 ^[90]	k -NN (1-NN), 聚类	台湾地区 1 号高速 公路(88km): 流量,速度, 行程时间	5min	MAPE: <8.6% MPE: <16.2%	鲁棒性强; 结合聚类和 回归模型 进行预测	性能受阈值 影响大;需要 定期校准 模型参数	高速公路 短期 长距离 预测
Tak 等人 ^[91]	k -NN (Mk-NN), GA	韩国高速公路 网(1800km): 速度	0~6h	MAPE:<3.3% RMSE:<3.5%	多层次匹配 减少计算量; 鲁棒性强	需要手动 整理和 标识数据	高速公路 长距离 长期预测
Hamner 等人 ^[92]	RF, 主成分 分析	华沙大学 仿真实验: 速度,流量	6min~30min	RMSE: <7.5%	能提取 数据的局部 和聚合特征	仿真实验 和真实状况 有差异	城市路网 短期预测
Zhang 等人 ^[9]	GB	I-95S 高速公路: 行程时间	5min~30min	高峰期 MAPE: 8.7%~18.4% 非高峰期 MAPE: 2.3%~14.8%	具有可解释性; 能揭示交通 数据潜在模式; 能捕捉交通 状况的突变	要避免 过拟合; 受参数 影响大	高速公路 短期预测
Yu 等人 ^[94]	RF, k -NN	沈阳市 232, 249 路公交: 行程时间		MAPE: 6.9%~14.29%	k -NN 预选数据 提高了 RF 的性能; 对异常值不敏感	计算量较大; 训练时间长	城市道路 网络
Gupta 等人 ^[95]	RF, GB	波尔图市 出租车: 经纬度,速度		RF:MRE: 17%~29% GB:MRE: 24%~29%	RF 训练速度 更快;GB 性能更好	需在准确率和 计算复杂度 之间权衡;受 参数影响大	城市道路 网络

注:MAPE:平均绝对百分比误差;MRE:平均相对误差;MAE:平均绝对误差;ME:平均误差;MSE:平均平方误差;
MARE:平均绝对值相对误差;MPE:平均百分比误差;RMSE:均方根误差;RRSE:相对方根误差

3.2.1 参数方法

本文讨论行程时间预测的 3 种最常见的参数方法,即线性回归、自回归集成移动平均和卡尔曼滤波方法。

(1) 线性回归

线性回归(linear regression,简称 LR)的基本思想是,假设函数是变量的线性组合。一些研究人员致力于使用线性回归模型预测行程时间。

Kwon 等人^[24]使用 LR 方法与逐步变量选择方法以及基于树的方法估算高速公路未来行程时间。实验结果表明:LR 模型在预测时长不超过 20min 时,与基于树的方法性能相当,历史数据对于长期预测的贡献更大,总体平均绝对百分比误差不超过 23%。Zhang 等人^[47]使用 LR 模型预测高速公路行程时间,其中,模型系数是出发时间的平滑函数。因此,这种方法需要预先存储不同出发时间的模型参数。I-880 和 I-405 数据集上的实验结果表明:当预测范围不超过 60min 时,I-880 数据集上的预测误差为 5%~24%;当预测时间范围从 0 逐渐增加到 90min 时,I-405 数据集上的预测误差从 8%逐渐增加到 14%。Rice 等人^[48]也提出了具有时变系数的 LR 方法,结合当前交通状况和历史数据进行预测,并使用 I-10E 的高速公路数据进行实验。结果表明,未来 1h 预测行程时间的均方根误差低于 10min。Sun 等人^[49]提出了多变量局部 LR 模型拟合未来流量和历史以及当前流量之间的关系,实验结果表明:局部线性回归性能优于最近邻和核平滑方法,平均相对误差为 11.38%。我们认为:由于最近邻和核平滑方法仅使用历史平均来预测行程时间,当前数据只用于计算权重,而多变量局部回归使用当前数据进行预测,因而能捕获近期交通状况,获得更好的预测效果。此外,Fei 等人^[22]也使用 LR 方法对行程时间进行了预测。

(2) 自回归集成移动平均

1976 年,Box 和 Jenkins 等人^[25]提出了时间序列预测的自回归集成移动平均模型(autoregressive integrated moving average model,简称 ARIMA),并指出:许多时间序列去除局部趋势后,序列的其中一部分与其他部分呈现出相似性。具体地说,ARIMA 是指将非平稳时间序列转化为平稳时间序列,然后对因变量和随机误差的当前

值和滞后值进行回归所建立的模型^[25]。

Oda 等人^[50]使用 ARIMA 模型进行了实验.当假设车辆长度为常量时,行程时间平均预测误差为 13.9%;当车辆平均长度变化时,行程时间平均预测误差为 6.8%.此外,Saito^[51]和 Ishak^[52]等人也使用了 ARIMA 模型来预测行程时间.Voort 等人^[53]将 Kohonen 网络和 ARIMA 模型结合,其中,Kohonen 网络用于聚类.Zhicharevich 等人^[54]使用 KARIMA 模型研究高速公路的实时短期行程时间预测问题.Williams 等人^[55]提出了季节性自回归集成移动平均模型(seasonal ARIMA,简称 SARIMA).SARIMA 在 ARIMA 的基础上添加了季节周期性变量,这是实现高精度的关键特征^[55].Xia 等人^[56]提出一个 SARIMA 结合自适应卡尔曼滤波器的多阶段行程时间预测器,该模型在新数据实时可用时,能够不断调整预测结果.使用 I-80 高速公路数据预测未来 5min 的行程时间,平均绝对百分比误差为 5.34%.然而,这种方法在交通拥堵和发生事故时性能降低.我们认为:这是由于卡尔曼滤波器的更新频率不够高,无法及时使用实时数据进行参数调整.Sun 等人^[57]使用浮动车数据对城市任意出发地和目的地之间的行程时间进行了预测,结果显示:SARIMA 和卡尔曼滤波器的混合模型的性能优于单独的卡尔曼过滤器和 SARIMA 模型,平均绝对误差和平均绝对百分比误差均小于 7%.由于季节性分析能够提取交通的周期性模式,而卡尔曼滤波能适应实时交通状况,季节性分析消除了卡尔曼滤波方法的滞后性,因而混合模型性能更好.

(3) 卡尔曼滤波

卡尔曼滤波(Kalman filtering,简称 KF)理论^[26]在 20 世纪 60 年代被美国数学家 Kalman 提出.KF 方法采用状态方程和观测方程组成的线性随机系统的状态空间模型,按线性无偏最小均方差估计准则,采用递推算法对状态变量作出最佳估计,从而求得滤掉噪声的数据的最佳估计.KF 方法在交通领域已被用于预测交通流量^[26]、旅行分布和交通密度估计^[58]以及实时需求转移^[59]等方面.由于行程时间受到各种因素的严重影响,动态行程时间的变化没有严格的规律.KF 方法可以利用行程时间的动态变化来进行预测^[60]。

Ji 等人^[61]根据 KF 模型,使用浮动车速度数据动态预测行程时间.由于时间和空间的连续性,在某些路段获得行驶时间观测值时,可以不断更新模型并预测行程时间.实验平均相对误差为 1.6%.Chen 等人^[62]也使用 KF 进行动态行程时间预测.仿真实验结果显示,该模型的相对方根误差小于 2.8%.Ojeda 等人^[63]提出了在线预测行程时间的自适应 KF 方法,该方法使用 CTM 对密度和流量进行预测,然后通过 KF 方法预测行程时间,将路口预测行程时间和道路上预测行程时间之和作为最终预测结果.仿真实验结果显示,该模型预测错误率小于 9%.Liu 等人^[64]提出了增强型 SES 模型(ESES)方法预测短期行程时间.SES 由于简单而被广泛使用^[65],可以预测短期时间序列.应用于交通预测时,如果未来的交通状况与历史数据基本一致,SES 表现良好^[66].然而由于静态性,SES 无法适应突发事件.KF 能在连续时间间隔内优化平滑因子,改善 SES 在突发状况的性能.具体来说,该模型将时变平滑因子引入 ESES,预测的行程时间是历史和实时行程时间的加权平均值.实验结果表明,ESES 性能优于 KF 和 SES.

3.2.2 非参数方法

由于参数模型固有的缺点以及越来越多的数据可用,非参数模型逐渐被研发出来.本文主要讨论 4 种非参数方法:神经网络、支持向量回归、最近邻和集成学习方法.

(1) 神经网络

1943 年,Pitts^[67]提出了神经网络的数学模型.此后,神经网络逐渐为研究人员们所推崇,并已应用于信息^[68]、生物学^[69]、交通^[70]等多个领域.

对于行程时间预测问题,神经网络模型一般使用行程时间或者速度等时间序列数据作为网络的输入,利用历史数据对模型参数进行训练,目标是调整网络参数,以最小化网络实际输出和期望输出之间的差异,最后使用训练好的模型预测行程时间.行程时间预测的神经网络一般有反向传播网络、循环神经网络、长短期记忆网络和状态空间网络.这些网络在结构上不尽相同,用于预测行程时间时有各自的优缺点.

i. 反向传播神经网络

反向传播神经网络(back propagation neural network,简称 BPNN)使用反向传播算法^[27]进行参数调优.BPNN 内部的每一层神经元只与下一层神经元连接,同一层内的神经元相互独立.

Park 等人^[71]考虑了上、下游道路的交通参数信息,结合历史行程时间和实时行程时间数据,使用单隐层 BPNN 进行建模.实验使用 US-290 高速公路数据,并设计了 NN_M1,NN_M2,NN_M3,NN_M4 这 4 个模型.其中,NN_M1 只使用目标道路数据,NN_M2 使用目标道路和相邻上下游两条道路的数据,NN_M4 使用目标道路和相邻上下游 4 条道路的数据,NN_M3 使用目标道路和最相关上下游两条道路的数据.结果显示:短期预测 NN_M1 性能最优,较长期预测 NN_M2 性能最优,所有模型的平均绝对百分比误差为 7.4%~18%.我们认为:考虑相邻道路数据能帮助提高模型长期预测的性能,因为基于运动波理论,上下游的交通状态会影响目标道路的行程时间.Chen 等人^[72]结合单隐层 BPNN 和数据融合方法动态预测行程时间,提出了空间离散化行程时间计算算法(SDTCM)和速度集成行程时间计算方法(SITCM).实验结果显示:SDTCM 比 SITCM 更准确,而 SITCM 比 SDTCM 更平稳.这是由于 SDTCM 是通过分段计算行程时间,而 SITCM 则是通过拟合速度函数然后求微积分来计算行程时间.Wisitpongphan 等人^[10]建立了具有 3 个隐层的 BPNN 模型,使用 GPS 数据预测未来 3h 的行程时间.该模型能实时使用行程时间数据,获取当前道路状况.实验结果显示,该模型的平均平方误差小于 3%.

ii. 循环神经网络

1982 年,Hopfield^[30]提出了一种时间递归神经网络模型,这是原始的循环神经网络(recurrent neural network,简称 RNN).随着研究的深入,RNN 逐渐被应用到交通领域.传统神经网络不具有上下文信息,因此对很多序列数据处理问题无能为力.而 RNN 结构中隐层的输入不仅包括输入层的输入,还包括上一时刻隐层的输出,在时间序列任务上表现出了优异的性能.

Yun 等人^[73]采用 3 种神经模型:单隐层 BPNN、有限脉冲响应模型(finite impulse response,简称 FIR)^[74]和延时循环网络(time-delayed recurrent network,简称 TDRN)模型,使用州际高速公路、城际高速公路和城市交叉路口这 3 组代表不同交通状况的数据进行实验,结果表明:TDRN 对于随机数据的预测准确率更高,而 FIR 对于相对规则的周期性数据性能更好.我们认为:这是因为 TDRN 能够学习时间相关的非线性变化,却只能保存短时间的记忆;而 FIR 的线性滤波器相比具有静态权值的 BPNN 能够更好地捕获数据的潜在模式.Abdulhai 等人^[75]使用遗传算法(genetic algorithm,简称 GA)改善 TDRN 的性能.仿真实验结果表明,该模型的平均百分比误差低于 15%.Dia 等人^[76]讨论了一种面向对象的 TDRN 模型,用来预测高速公路上未来 15min 的速度,平均百分比误差为 7%.TDRN 网络具有短期记忆结构,更适合于非线性预测、系统识别和模式分类.

iii. 长短期记忆神经网络

鉴于 RNN 难以保留长期记忆,Hochreiter 等人^[31]提出了长短期记忆网络(long short-term memory,简称 LSTM).在 LSTM 内部,RNN 的常规神经元被 LSTM 存储单元代替,每个存储单元由输入门、忘记门和输出门构成.信息流从 3 个门流入:输入门决定是否传入激活信息,输出门决定是否传出信息,忘记门决定是否丢弃信息.

Duan 等人^[77]使用 LSTM 神经网络模型预测行程时间.历史行程时间数据按顺序输入网络,依次输出预测的未来行程时间.实验结果表明:随着预测范围从 15min 逐渐增加到 1h,平均相对误差从 0.17 增加到 0.77.王飞跃等人^[78]提出了 LSTM 路段行程时间预测方法,该模型可以挖掘行程时间数据的短期和长期关联模式,并根据当前状态自动调整历史信息对当前预测的权重.Liu 等人^[79]提出了由 LSTM 层、深度全连接层堆叠构成的 LSTM-DNN(long short term memory-deep neural network)模型,并设计了具有不同网络结构的多个模型.实验结果表明,该模型对未来 1h 的行程时间预测平均绝对百分比误差低于 7.3%.虽然该模型准确率较高,但需要大量的时间来确定网络结构参数和训练模型.值得注意的是,该模型在历史数据较少、预测区间较长时性能也比较稳定.其原因可能是深层的网络结构充分提取了交通数据的潜在模式.

iv. 状态空间神经网络

状态空间神经网络(state space neural network,简称 SSNN)是循环神经网络的一种形式,具有一个上下文层和一个隐层,且上下文层和隐层间相互连接.数据由输入层传入隐层,隐层神经元接收当前输入和上下文状态神经元的状态,然后经过非线性变换后传递到输出层.上下文状态神经元保存的是上一时刻隐层神经元的状态.SSNN 结构如图 3, $u_{t,i}$ 和 $x_{t,i}$ 分别表示时刻 t 第 i 条道路的输入和上下文状态, $x_{t+1,i}$ 是时刻 t 隐层的状态, y_{t+1} 表示时刻 t 网络的预测输出.

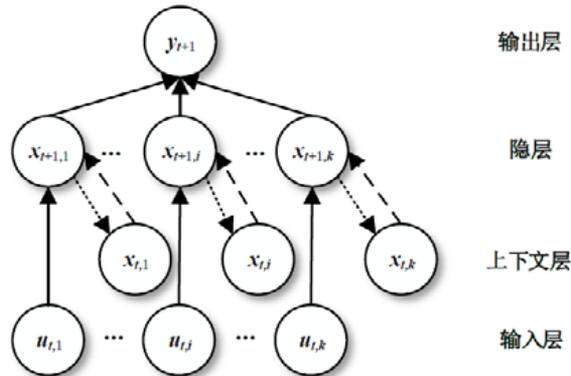


Fig.3 Structure of SSNN

图3 SSNN 结构图

Lint 等人^[32]使用了 3 种 SSNN 模型:全连接状态空间神经网络(FC-SSNN)、简化状态空间神经网络(R-SSNN)和局部连接状态空间神经网络(PC-SSNN).其中:FC-SSNN 的上下文和隐层之间完全连接;R-SSNN 是 FC-SSNN 的简化,它会删去对输入数据没有贡献的隐层神经元;PC-SSNN 的每个隐层神经元只连接到它自己的上下文神经元和相邻神经元.仿真实验的平均相对误差小于 10%.Lint 等人^[80]提出一个结合 SSNN、简单指数平滑和空间插值方法的行程时间预测框架,通过对缺失数据的处理,该模型具有了较好的鲁棒性.仿真实验结果获得了 1.6%的平均相对误差.Li 等人^[81]提出了利用终止条件控制训练过程的贝叶斯状态空间神经网络(Bayesian state space neural network,简称 BSSNN),该模型使用控制因子限制预测结果的置信区间,缩短了训练时间,加速了收敛过程且稳定性增强.相比 SSNN 模型,BSSNN 训练时间从 179min 缩短到了 89min,平均绝对百分比误差降低了 0.17%.

(2) 支持向量回归

自从 Vapnik 等人^[82]提出支持向量机(support vector machine,简称 SVM)后,研究者们已经对 SVM 分类和回归进行了深入研究^[33,34].SVM 能根据训练样本,在模型复杂度和泛化能力之间寻求最佳折中.基于 SVM 的支持向量回归(support vector regression,简称 SVR)方法也逐渐被用作非线性拟合的一种常用方法.SVR 的基本思想是:通过拟合一个函数,将难以在低维空间分离的数据映射到多维特征空间,然后构造出具有最大边界的分离超平面.

Wu 等人^[83]应用 SVR 模型,使用台湾地区高速公路局收集的车速数据间接预测行程时间.实验设计了以线性函数、多项式函数和径向基函数为核函数的 3 个模型.实验结果表明:相比历史平均方法等基线模型,SVR 模型的平均相对误差减少了 3%~10%,均方根误差减少了 4%~24%.Castro-Neto 等人^[84]提出了在线支持向量回归机(online-SVR,简称 OL-SVR)用于交通预测.每次向 OL-SVR 模型添加新数据时,模型参数都会发生变化.随着不断接收的实时数据,可以在不断产生新的预测值的同时更新模型.实验结果显示:在道路畅通时,平均绝对百分比误差低于 9%;交通拥堵时,平均绝对百分比误差低于 23.4%.Gao 等人^[85]将 SVR 和免疫遗传算法(immune genetic algorithm,简称 IGA)结合,预测行程时间.IGA 通过模拟生物免疫系统来改进遗传算法,本质是将优化问题的目标函数作为抗原,将优化问题的最优解作为抗体,通过模拟生物免疫系统来学习、记忆和自适应调节^[86].结合 IGA 能够提高 SVR 对交通状态变化的适应能力,避免陷入局部最优.实验表明,该模型的平均绝对百分比误差为 12.4%.

(3) 最近邻

最近邻(nearest neighbor,简称 NN)算法也叫作 k 近邻(k -NN),是机器学习算法中的一种简单却广泛应用的分类型算法. k -NN 的思想是:如果一个样本在特征空间中的 k 个最相似样本大多数属于某一类别,则该样本也属于这一类别. k -NN 回归方法使用相似的历史数据来预测未来值,因此 k -NN 的有效性直接取决于数据库的质量^[28]. k -NN 预测方法有很多,如取近邻平均值、加权平均值或对近邻进行线性或非线性拟合来预测未来值等^[87].

Bajwa 等人^[88]使用 k -NN 模型预测行程时间.该模型对相似模式的行程时间进行提取和清洗,然后取均值作为最终预测行程时间.实验的均方根误差低于 12.5%.由于该模型假设交通状况是周期性的,因此在交通状况突变时,无法准确预测行程时间.Lim 等人^[89]使用 k -NN 方法,结合点检测系统和区间检测系统来预测交通参数,估计行程时间.点检测系统代表了实时交通状态,用于将时间平均速度转换为空间平均速度;区间检测系统反映了动态交通状态,用于直接测量路段的行程时间.实验结果表明,预测时间范围为 5min~30min 的平均绝对百分比误差为 4.3%~14.8%.Wang 等人^[90]开发了一个带有阈值和线性回归的改进的 1-NN 模型,用于推导真实行程时间和不同数据源收集到的交通数据间的关系,以找出行程时间日变化或周变化的潜在趋势,从而预测近期交通状况.实验数据显示:该模型的平均绝对百分比误差低于 8.6%,平均百分比误差低于 16.2%.Tak 等人^[91]提出了实时行程时间预测的多层 k -NN(multilayer k -nearest neighbor,简称 Mk -NN)框架^[91].该框架使用多个层次模式匹配,即分类匹配、全局匹配和局部匹配,下一层次的匹配过程从上一层匹配的数据集中选取数据.这种多层匹配减少了搜索空间和计算量,缩短了预测时间.预测结果是多个匹配数据的加权平均和,权重由遗传算法(GA)进行优化.实验结果表明: Mk -NN 模型比传统 k -NN 快了 8 倍,且平均绝对百分比误差和均方根误差都小于 3.5%.

(4) 集成学习

集成学习方法是一种提升分类准确率的机器学习方法,它的主要思想是:将多个分类算法聚集在一起,根据多个分类器的投票结果进行预测.集成学习方法可以处理不同类型的变量,适应复杂的非线性关系.集成学习方法已被用于解决许多交通领域问题.

Hamner 等人^[92]应用上下文依赖的随机森林方法(random forests,简称 RF)来预测行程时间.RF 是多个决策树的组合,每棵树都是某种特征的分类或回归专家,最终结果是所有树的投票结果,优于单个分类器^[93].模拟实验使用道路上 1%车辆的 GPS 数据,均方根误差值低于 7.5%.Zhang 等人^[9]采用梯度提升方法(gradient boosting,简称 GB)预测高速公路的行程时间.该模型能处理急剧的不连续性,这是对交通状况突变进行建模的重要特征.结果显示,GB 模型的性能相对 RF 有略微提升.这是因为 RF 的训练集是随机选择的;而 GB 在生成新树时更加注重错误预测的训练样本,因而能生成分类能力更强的树.预测范围为 5min~30min 时,高峰期平均绝对百分比误差不超过 18.4%;非高峰期不超过 14.8%.Yu 等人^[94]使用基于近邻的随机森林方法(random forests based on near neighbors,简称 RFNN)预测公交行程时间.该方法使用 k -NN 对 RF 的训练集进行预选,因为相似的样本可能具有相似的模式或交通状况,从而具有相似的行程时间. k -NN 方法的使用能提高训练集的质量,有助于提高 RF 的性能.实验使用沈阳市两条公交线路的行程时间数据,结果显示,平均绝对百分比误差低于 14.3%.Gupta 等人^[95]用 RF 和 GB 模型预测出租车行程时间.实验使用波尔图市的出租车数据,RF 和 GB 的平均相对误差都不超过 30%.通过分析实验结果发现:GB 比 RF 性能更好,而 RF 能采取并行训练方式所以训练速度更快.

4 开放问题

虽然现有行程时间预测方法中已经具有较好的性能,但是仍然存在一些问题.

4.1 数据预处理

用于行程时间预测的交通数据来源有很多,这些数据具有异构和高维特性.此外,数据可能会缺失或出错,因此有必要进行数据预处理.Wu 等人^[96]将数据清洗与数据分析融合,提出了一种噪声感知的数据挖掘算法检测和消除噪声.Qu 等人^[97]提出了基于概率主成分分析的缺失数据插补算法.其他类似的数据插补研究还有文献[98,99].现有的数据插补算法大都假设噪声是某种已知的形式,而现实中数据噪声通常是随机的,难以用一个明确定义的概率分布函数来表征^[96].因此,研究新的数据插补算法或者消除算法的假设是一个研究方向.此外,高维的交通数据可能存在维度诅咒问题,因此,需要研发有效的数据降维方法,如考虑张量分解算法的改进方案等.过多数据可能会导致模型(如 k -NN)的计算量过大,实时性要求难以满足.使用聚类方法挑选高质量的数据是一个可行方法.

根据上面的分析,我们提出了一种新的数据预处理框架,如图 4 所示.该框架分为在线和离线处理两部分.

- 离线处理主要有两步:1) 日期分类,即从原始交通数据库中提取相关交通数据,并按照工作日、周末、

节假日进行分为 3 类(或者按照周一到周日、节假日分为 8 类);2) DBSCAN 聚类,即对日期分类后的每一类数据使用 DBSCAN 方法进行聚类,并存储到新的交通数据库中;

- 在线数据处理分为 4 步:1) 标记异常数据,从待处理数据中发现异常数据并进行标识;2) 对标识的异常数据根据日期进行分类;3) 寻找 k 近邻,即针对日期分类后的异常数据在分类数据库中使用 KNN 方法寻找最相似的 K 个近邻;4) 计算 K 个近邻的均值,并用均值来替换源数据中的异常数据.

该框架中的分类数据库可以根据需求进行周期性更新.该框架的优势在于能够根据日期对交通数据进行划分,避免了节假日和周末不同交通模式的影响,通过聚类方法进一步缩小搜索空间,通过 KNN 方法对异常数据进行插补和替换,从而使得数据库更加健全,减少了异常数据对交通预测研究的影响.

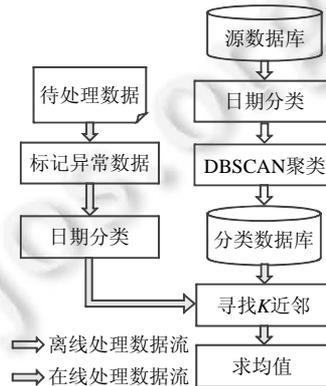


Fig.4 Framework of data processing

图 4 交通数据处理框架

4.2 结合空间信息

目标线路的行程时间会受到周围相邻道路的交通状况的严重影响,很多事故检测算法使用上下游相关的交通流参数^[100,101].因此,捕获相邻道路的空间信息能提高行程时间预测的准确度.如何高效地结合空间信息与时间信息,仍旧值得深入研究.Park 等人^[71]使用皮尔逊相关系数来度量道路之间相关性.设计更加合适的道路相关性度量方法有可能帮助提高行程时间预测方法的准确度,如尝试使用欧氏距离、余弦距离等作为道路的相关性度量.此外,需要及时获取空间相关信息的变化状况,如道路发生交通拥堵等,这样可以避免由于交通状况突变而导致的模型性能降低.可以使用数据挖掘算法对实时获取的交通数据进行分析,挖掘当前交通模式,以确定当前交通状况是否发生变化.

4.3 混合预测算法

现有的大多数数据驱动方法的可解释性较差,相对可解释的模型如 SSNN, k -NN,RF 和 GB 等更具有说服力.考虑 Tak 等人^[91]提出的分层 k -NN 方法能够在保证准确度的同时降低计算量,Yu 等人^[94]将 RF 和 k -NN 方法结合,提高了预测准确率.这些方法启发我们,混合预测算法可能具有更好的性能.状态空间神经网络(SSNN)能够捕获邻近道路的相关信息,即空间信息,具有上一时刻的状态信息,即短期记忆,随着时间推进,SSNN 无法记忆更长时间的信息.因此,将 SSNN 和长短期记忆网络(LSTM)相结合,有可能提高 SSNN 模型的预测准确率.此外,可以使用多层 k -NN 方法选择梯度提升树模型的训练本来提高模型的预测准确率.

4.4 深度学习算法

2006 年以来,深度学习方法发展迅速,并且已经成功应用于计算机视觉^[102]、语音识别^[103]以及自然语言处理^[104]等多个领域.然而,深度学习应用于交通领域的研究相对匮乏.因此,未来可以尝试将深度学习用于行程时间预测.受限玻尔兹曼机(restricted Boltzmann machine,简称 RBM)^[105]可以通过输入的数据学习概率分布,并已

应用于降维、分类和特征学习中.多个 RBM 堆叠成的深度信念网络能学习数据的潜在周期和趋势,因此,使用深度信念网络预测行程时间有一定的研究意义.

4.5 通用预测方法

已有的行程时间预测方法大多适用于高速公路,城区行程时间预测的研究很少,而人们的日常出行大都在城区范围.因此,将预测方法应用于城区范围具有重要的现实意义.此外,现有预测模型大都针对特定的地点,可转移性差.开发一类通用的行程时间预测方法,是一个极具挑战性的任务.

4.6 拟议预测方法

2015 年,Shi 等人^[106]提出了卷积长短期记忆网络(convolutional long-short term memory,简称 convLSTM).该网络能够结合数据的空间相关信息,同时能挖掘时间序列的潜在模式.Yuan 等人^[107]已经将该方法应用于交通事故预测,并取得了不错的结果.因此,我们认为,convLSTM 在交通领域是一个有潜力的方法.本文拟议的行程时间预测模型如图 5 所示.我们可以通过根据包括起始地和目的地在内的一个道路网络图和每一条边(短路径)需要花费的历史行程时间,来预测出发地到目的地的每条路线的行程时间.具体来说,在道路网络图中,从出发地到目的地的每一条路线都是由多个短路径构成的.通过提取历史交通数据库中路网的每条短路径的历史行程时间,我们可以获得一个三维的历史行程时间张量.convLSTM 模型接收该三维张量,并输出未来一段时间内每一条短路径的行程时间.旅客从起始地到目的地的预测行程时间可以通过计算每一个短路径的行程时间之和获得.例如,从图 5 中的出发地到目的地有多条路线,其中,路线一由 (r_1, r_2, r_3, r_4) 构成,路线二由 (r_5, r_6, r_7, r_4) 构成,则 convLSTM 模型对路线一和二的预测出行时间分别为 $(t_1+t_2+t_3+t_4)$ 和 $(t_5+t_6+t_7+t_4)$.该模型能够结合地理空间位置关系和行程时间的时序关系,且能同时预测整个道路网络的行程时间.缺点是 convLSTM 的网络结构需要通过实验进行确定,训练时间相对较长.值得一提的是,当新的行程时间数据可用时,可以在一个固定周期(例如每天或每周)使用最新的数据对模型进行离线更新,以提高模型的性能.

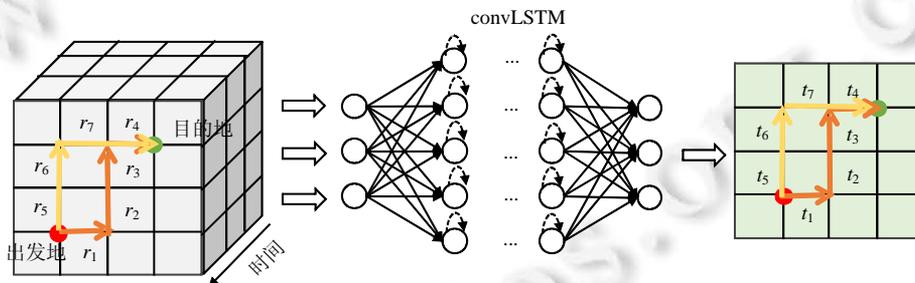


Fig.5 Proposed model of travel-time prediction

图 5 提议的行程时间预测模型

5 总结

本文总结了自 20 世纪 90 年代起,近 50 篇行程时间预测相关文献介绍的方法.基于理论和模型的差异,这些方法被分为模型驱动方法(排队论和细胞传输模型)和数据驱动方法(包括参数方法(线性回归、自回归集成移动平均和卡尔曼滤波)和非参数方法(神经网络、支持向量回归、最近邻和集成学习)).

模型驱动方法大都适用于较短距离的短期(不超过 30min)行程时间预测,且随着预测时间的增加,模型准确度逐渐降低.预测模型一般需要考虑交叉路口的信号灯周期以及等待队列长度等信息,需要具备一定的交通流知识,适用于高速公路和城区道路.模型驱动方法的优势是已经有比较成熟和完善的交通流模型和理论体系,能够明确地解释各个交通量之间的关联,只需要对特定道路情况进行建模并计算,且模型的参数较少.模型驱动方法的一个最大缺陷是地点特定,转移到其他地点需要重新建模和确定交通参数.

数据驱动方法既可以用于短期预测,也可以用于长期预测.大部分数据驱动方法能在预测时间增加的同时

保证一定的准确率.数据驱动方法适用于高速公路上的行程时间预测,在城区道路上的行程时间预测的相关研究较少.数据驱动方法的共同优势在于直接从数据中挖掘模式,不需要交通流建模方面的知识.大多数的数据驱动方法能够对非线性、高维的数据进行时间和空间特征处理,具有一定的泛化能力、自适应能力和容错能力.然而,数据驱动方法大都具有较多参数,计算量大,需要花费较长时间训练模型,且需要在准确率和模型复杂度之间寻求折中.缺乏可解释性也是大多数数据驱动方法的缺点.只有少数的数据驱动方法如 k -NN 和 SSNN 以及集成学习方法具有一定的可解释性.

本文指出了行程时间的未来研究方向以及现存的行程时间预测方法中存在的问题的一些可能的解决方案.此外,本文提出了一种新的数据处理框架和行程时间预测模型.虽然针对行程时间预测问题已经存在大量的研究,但高效准确的预测方法的研究仍具有重要意义.

References:

- [1] Mahmassani, HS, Peeta S. System optimal dynamic assignment for electronic route guidance in a congested traffic network. In: Proc. of the Urban Traffic Networks: Dynamic Flow Modeling and Control. Berlin, Heidelberg: Springer-Verlag, 1995. 3–37.
- [2] Ho FS, Ioannou P. Traffic flow modeling and control using artificial neural networks. IEEE Control Systems Magazine, 1996,16(5): 16–26.
- [3] Chabini, Ismail. Discrete dynamic shortest path problems in transportation applications: Complexity and algorithms with optimal run time. Transportation Research Record: Journal of the Transportation Research Board, 1998,1645:170–175.
- [4] Stephanedes YJ, Chassiakos AP. Freeway incident detection through filtering. Transportation Research Part C (Emerging Technologies), 1993,1(3):219–233.
- [5] Figueiredo L, Jesus I, Machado JAT, Ferreira JR, Carvalho JLMD. Towards the development of intelligent transportation systems. In: Proc. of the Intelligent Transportation Systems. IEEE, 2001. 1206–1211.
- [6] Zhang J, Wang FY, Wang K, Lin WH, Xu X, Chen C. Data-Driven intelligent transportation systems: A survey. IEEE Trans. on Intelligent Transportation Systems, 2011,12(4):1624–1639.
- [7] Khattak AJ, Targa F, Yim Y. Advanced Traveler Information Systems. 2004.
- [8] Heathington KW. On the development of a freeway driver information system. In: Proc. of the Real Time Information. 1969.
- [9] Zhang Y, Haghani A. A gradient boosting method to improve travel time prediction. Transportation Research Part C: Emerging Technologies, 2015,58:308–324.
- [10] Wisitpongphan N, Jitsakul W, Jieamumporn D. Travel time prediction using multi-layer feed forward artificial neural network. In: Proc. of the 4th Int'l Conf. on Computational Intelligence. IEEE, 2012. 326–330.
- [11] Chen H, Rakha HA. Multi-Step prediction of experienced travel times using agent-based modeling. Transportation Research Part C: Emerging Technologies, 2016,71:108–121.
- [12] Wei CH, Lee Y. Development of freeway travel time forecasting models by integrating different sources of traffic data. IEEE Trans. on Vehicular Technology, 2007,56(6):3682–3694.
- [13] Yeon J, Elefteriadou L, Lawphongpanich S. Travel time estimation on a freeway using discrete time Markov chains. Transportation Research Part B: Methodological, 2008,42(4):325–338.
- [14] Chrobok R, Hafstein SF, Pottmeier A. OLSIM: A new generation of traffic information systems. Journal of Information Science & Technology, 2013,3(2):883–886.
- [15] Messmer A, Papageorgiou M. METANET: A macroscopic simulation program for motorway networks. Traffic Engineering and Control, 1990,31(8):466–470.
- [16] Oh S, Byon YJ, Jang K, Yeo H. Short-Term travel-time prediction on highway: A review on model-based approach. KSCE Journal of Civil Engineering, 2018,22(1):298–310.
- [17] Takaba S, Morita T, Hada T, Usami T. Estimation and measurement of travel time by vehicle detectors and license plate readers. In: Proc. of the Vehicle Navigation and Information Systems Conf. 1991. 257–267.
- [18] Daganzo C. The Cell Transmission Model. Part I: A Simple Dynamic Representation of Highway Traffic. 1992. 288.
- [19] Chrobok R. Theory and Application of Advanced Traffic Forecast Methods. 2005.

- [20] Hinsbergen CPI, Lint JWCV, Sanders FM. Short term traffic prediction models. In: Proc. of the 14th World Congress on Intelligent Transport Systems. 2007. 7.
- [21] Yu J, Chang GL, Ho HW, Liu Y. Variation based online travel time prediction using clustered neural networks. In: Proc. of the IEEE Int'l Conf. on Intelligent Transportation Systems. 2008. 85–90.
- [22] Fei X, Lu CC, Liu K. A Bayesian dynamic linear model approach for real-time short-term freeway travel time prediction. *Transportation Research Part C*, 2011,19(6):1306–1318.
- [23] Oh S, Byon YJ, Jang K, Yeo H. Short-Term travel-time prediction on highway: A review of the data-driven approach. *Transport Reviews*, 2015,35(1):4–32.
- [24] J Kwon J, Coifman B, Bickel P. Day-to-Day traveltime trends and travel-time prediction from LoopDetector data. *Transportation Research Record: Journal of the Transportation Research Board*, 2000,1717:120–129. [doi: 10.3141/1717-15]
- [25] Box GEP, Jenkins GM. Time series analysis, forecasting and control. *Journal of the American Statistical Association*, 1971,134(3): 343–344.
- [26] Okutani I, Stephanedes YJ. Dynamic prediction of traffic volume through Kalman filtering theory. *Transportation Research Part B: Methodological*, 1984,18(1):1–11.
- [27] Rumelhart DE, Hinton GE, Williams RJ. Learning representations by back-propagating errors. *Nature*, 1986,323(6088):399–421.
- [28] Yandell, Brian S. Spline smoothing and nonparametric regression. *Technometrics*, 1989,31(3):379–380.
- [29] Bai MT, Lin YX, Ma M, Wang P. Travel-Time prediction methods: A review. In: Proc. of the 3rd Int'l Conf. on SmartCom 2018. 2018. 67–77. [doi: 10.1007/978-3-030-05755-8_7]
- [30] Hopfield JJ. Neural networks and physical systems with emergent collective computational abilities. *Proc. of the National Academy of Sciences of the United States of America*, 1982,79(8):2554–2558.
- [31] Hochreiter S, Schmidhuber J. LSTM can solve hard long term lag problems. In: Proc. of the Neural Information Processing Systems Nips. 1997. 9.
- [32] Van Lint J, Hoogendoorn S, Van Zuylen H. Freeway travel time prediction with state-space neural networks: Modeling state-space dynamics with recurrent neural networks. *Transportation Research Record Journal of the Transportation Research Board*, 2002,1811:30–39.
- [33] Thissen U, Brakel RV, Weijer APD, Melssen WJ, Buydens LMC. Using support vector machines for time series prediction. *Chemometrics and Intelligent Laboratory Systems*, 2003,69(1-2):35–49.
- [34] Müller KR, Smola AJ, Rätsch G, Schölkopf B, Kohlmorgen J, Vapnik V. Predicting time series with support vector machines. *LNCS*, 1997,20(2):999–1004.
- [35] Kachroo P, Ozbay K, Hobeika AG. Real-Time travel time estimation using macroscopic traffic flow models. In: Proc. of the IEEE Intelligent Transportation Systems. 2001. 132–137.
- [36] Xu T, Hao Y, Sun L. Travel time prediction of urban expressway in unstable traffic flow. In: Proc. of the Int'l Conf. on Transportation Engineering. 2007. 2205–2210.
- [37] Skabardonis A, Geroliminis N. Real-Time estimation of travel times along signalized arterials. In: Proc. of the Transportation and Traffic Theory. 2005. [doi: 10.1016/b978-008044680-6/50022-2]
- [38] Ben-Akiva M, Bierlaire M, Burton D, Koutsopoulos HN, Mishalani R. Network state estimation and prediction for real-time traffic management. *Networks and Spatial Economics*, 2001,1(3-4):293–318.
- [39] Daganzo CF. The cell transmission model: A dynamic representation of highway traffic consistent with the hydrodynamic theory. *Transportation Research, Part B (Methodological)*, 1994,28(4):269–287.
- [40] Daganzo CF. A continuum theory of traffic dynamics for freeways with special lanes. *Transportation Research Part B (Methodological)*, 1997,31(2):83–102.
- [41] Daganzo CF. An Enhanced Cell-Transmission Rule for Traffic Simulation. 1997.
- [42] Tampere CMJ, Immers B. Traffic State Estimation and Prediction Using the Cell Transmission Model with Implicit Mode Switching and Dynamic Parameters. 2007.
- [43] Juri NR, Unnikrishnan A, Waller ST. Integrated traffic simulation-statistical analysis framework for online prediction of freeway travel time. *Transportation Research Record Journal of the Transportation Research Board*, 2007,2039:24–31.

- [44] Xiong Z, Rey D, Mao T, Liu H. A three-stage framework for motorway travel time prediction. In: Proc. of the IEEE Int'l Conf. on Intelligent Transportation Systems. 2014. 816–821.
- [45] Wan N, Gomes G, Vahidi A, Horowitz R. Prediction on travel-time distribution for freeways using online expectation maximization algorithm. In: Proc. of the Transportation Research Board 93rd Annual Meeting. 2014.
- [46] Seybold C. Calibration of fundamental diagrams for travel time predictions based on the cell transmission model. In: Proc. of the VS Verlag für Sozialwissenschaften. 2015. 207–220.
- [47] Zhang X, Rice JA. Short-Term travel time prediction. *Transportation Research Part C (Emerging Technologies)*, 2003,11(3-4): 187–210.
- [48] Rice J, Vanzwet E. A simple and effective method for predicting travel times on freeways. *IEEE Trans. on Intelligent Transportation Systems*, 2004,5(3):200–207.
- [49] Sun H, Liu H, Xiao H, He R, Ran B. Use of local linear regression model for short-term traffic forecasting. *Transportation Research Record: Journal of the Transportation Research Board*, 2003,1836:143–150.
- [50] Oda T. An algorithm for prediction of travel time using vehicle sensor data. In: Proc. of the Int'l Conf. on Road Traffic Control. 1990. 40–44.
- [51] Saito M, Watanabe T. Prediction and dissemination system for travel time utilizing vehicle detectors. In: Proc. of the Steps Forward, Intelligent Transport Systems World Congress. 1995.
- [52] Ishak S, Al-Deek H. Performance evaluation of short-term time-series traffic prediction model. *Journal of Transportation Engineering*, 2002,128(6):490–498.
- [53] Voort MVD, Dougherty M, Watson S. Combining kohonen maps with arima time series models to forecast traffic flow. *Transportation Research Part C (Emerging Technologies)*, 1996,4(5):307–318.
- [54] Zhicharevich A, Margalit Y. Travel Time Prediction Problem RTA Freeway.
- [55] Williams BM, Hoel LA. Modeling and forecasting vehicular traffic flow as a seasonal ARIMA process: Theoretical basis and empirical results. *Journal of Transportation Engineering*, 2003,129(6):664–672.
- [56] Xia J, Chen M, Huang W. A multistep corridor travel-time prediction method using presence-type vehicle detector data. *Journal of Intelligent Transportation Systems*, 2011,15(2):104–113.
- [57] Sun J, Zhang C, Chen SK, Xue R, Peng ZR. Route travel time estimation based on seasonal model and Kalman filtering algorithm. *Journal of Changan University*, 2014,34(6):145–151.
- [58] Okutani I. The Kalman filtering approaches in some transportation and traffic problems. In: Proc. of the Transportation and Traffic Theory. 1987.
- [59] Stephanedes YJ, Kwon E. Adaptive demand-diversion prediction for integrated control of freeway corridors. *Transportation Research Part C*, 1993,1(1):23–42.
- [60] Yang JS. Travel time prediction using the GPS test vehicle and Kalman filtering techniques. In: Proc. of American Control Conf., 2005. 2128–2133.
- [61] Ji H, Xu A, Sui X, Sui X, Li L. The applied research of Kalman in the dynamic travel time prediction. In: Proc. of the 18th Int'l Conf. on Geoinformatics: GIScience in Change, Geoinformatics 2010. 2010. 1–5.
- [62] Chen M, Chien S. Dynamic freeway travel-time prediction with probe vehicle data: Link based versus path based. *Transportation Research Record Journal of the Transportation Research Board*, 2001,1768(1):157–161.
- [63] Ojeda LRL, Kibangou AY, Wit CCD. Online dynamic travel time prediction using speed and flow measurements. In: Proc. of the Control Conf. 2013. 4045–4050.
- [64] Liu X, Chien SI, Chen M. An adaptive model for highway travel time prediction. *Journal of Advanced Transportation*, 2015,48(6): 642–654.
- [65] Gross D, Craig RJ. A comparison of maximum likelihood, exponential smoothing and Bayes forecasting procedures in inventory modelling. *Int'l Journal of Production Research*, 1974,12(5):607–622.
- [66] Makridakis S. The accuracy of extrapolation (time series) methods: Results of a forecasting competition. *Journal of Forecasting*, 2010,1(2):111–153.
- [67] Pitts. *History of Neural Computing*. 1943.

- [68] Krizhevsky A, Sutskever I, Hinton G. ImageNet classification with deep convolutional neural networks. In: Proc. of the Int'l Conf. on Neural Information Processing Systems. 2012. 1097–1105.
- [69] Erb M, Aertsen A. Dynamics of Activity in Biology-Oriented Neural Network Models: Stability at Low Firing Rates. 1992. 201–223.
- [70] Samant A, Adeli H. Enhancing neural network traffic incident-detection algorithms using wavelets. *Computer-Aided Civil and Infrastructure Engineering*, 2002,16(4):239–245.
- [71] Park D, Rilett LR. Forecasting freeway link travel times with a multilayer feedforward neural network. *Computer-Aided Civil and Infrastructure Engineering*, 2010,14(5):357–367.
- [72] Chen D, Zhang K, Liao T. Practical travel time prediction algorithms based on neural network and data fusion for urban expressway. In: Proc. of the 6th Int'l Conf. on Natural Computation. 2010. 1754–1758.
- [73] Yun SY, Namkoong S, Rho JH, Shin SW, Choi JU. A performance evaluation of neural network models in traffic volume forecasting. *Mathematical and Computer Modelling*, 1998,27(9-11):293–310.
- [74] Wan EA. Modeling nonlinear dynamics with neural networks: Examples in time series prediction. In: Proc. of SPIE, 1993. 327–232.
- [75] Abdulhai B, Porwal H, Recker W. Short Term Freeway Traffic Flow Prediction Using Genetically-Optimized Time-Delay-Based Neural Networks. 1999.
- [76] Dia H. An object-oriented neural network approach to short-term traffic forecasting. *European Journal of Operational Research*, 2001,131(2):253–261.
- [77] Duan Y, Lv Y, Wang FY. Travel time prediction with LSTM neural network. In: Proc. of the IEEE Int'l Conf. on Intelligent Transportation Systems. 2016. 1053–1058.
- [78] Wang FY, Duan YJ, Lv YS, Chen YY, Lin YL, Liu YL. One kind of link travel time forecasting method based on the lstm. Patent CN106096767A, 2016 (in Chinese).
- [79] Liu Y, Wang Y, Yang X, Zhang L. Short-Term travel time prediction by deep learning: A comparison of different LSTM-DNN models. In: Proc. of the IEEE Int'l Conf. on Intelligent Transportation Systems. 2017. 1–8.
- [80] J Lint JWCV, Hoogendoorn SP, Zuyleen HJV. Accurate travel time prediction with state-space neural networks under missing data. *Transportation Research Part C Emerging Technologies*, 2005,13(s 5-6):347–369.
- [81] Li X, Wang C, Shi H. A travel time prediction method: Bayesian reasoning state-space neural network. In: Proc. of the 2010 2nd Int'l Conf. on Information Science and Engineering (ICISE). 2010. 936–940.
- [82] Vapnik V. The nature of statistical learning theory. *Technometrics*, 1995,38(4):409–409.
- [83] Wu CH, Ho JM, Lee DT. Travel-Time prediction with support vector regression. *IEEE Trans. on Intelligent Transportation Systems*, 2004,5(4):276–281.
- [84] Castro-Neto M, Jeong YS, Jeong MK, Han LD. Online-SVR for short-term traffic flow prediction under typical and atypical traffic conditions. *Expert Systems with Applications*, 2009,36(3):6164–6173.
- [85] Gao P, Hu J, Zhou H, Zhang Y. Travel time prediction with immune genetic algorithm and support vector regression. In: Proc. of the World Congress on Intelligent Control and Automation. 2016. 987–992.
- [86] Tan GZ, Zhou DM, Jiang B, Dioubate MI. Elitism-Based immune genetic algorithm and its application to optimization of complex multi-modal functions. *Journal of Central South University of Technology*, 2008,15(6):845–852.
- [87] Smith BL, Williams BM, Oswald RK. Comparison of parametric and nonparametric models for traffic flow forecasting. *Transportation Research Part C (Emerging Technologies)*, 2002,10(4):303–321.
- [88] Bajwa SI, Chung E, Kuwahara M. Performance evaluation of an adaptive travel time prediction model. In: Proc. of the IEEE Intelligent Transportation Systems. 2005. 1000–1005.
- [89] Lim S, Lee C. Data fusion algorithm improves travel time predictions. *IET Intelligent Transport Systems*, 2011,5(4):302–309.
- [90] Wang JY, Wong KI, Chen YY. Short-Term travel time estimation and prediction for long freeway corridor using NN and regression. In: Proc. of the Int'l IEEE Conf. on Intelligent Transportation Systems. 2012. 582–587.
- [91] Tak S, Kim S, Oh S, Yeo H. Development of a data-driven framework for RealTime travel time prediction. *Computer-Aided Civil and Infrastructure Engineering*, 2016,31(10):777–793.

- [92] Hamner B. Predicting travel times with context-dependent random forests by modeling local and aggregate traffic flow. In: Proc. of the IEEE Int'l Conf. on Data Mining Workshops. 2011. 1357–1359.
- [93] Liaw A, Wiener M. Classification and regression by randomForest. R News, 2002,2(3):18–22.
- [94] Yu B, Wang H, Shan W, Yao B. Prediction of bus travel time using random forests based on near neighbors. Computer-aided Civil and Infrastructure Engineering, 2017,33(2):333–350.
- [95] Gupta B, *et al.* Taxi Travel Time Prediction Using Ensemble-based Random Forest and Gradient Boosting Model. 2018.
- [96] Wu X, Zhu X. Mining with noise knowledge: Error-aware data mining. IEEE Trans. on Systems, Man, and Cybernetics-Part A: Systems and Humans, 2008,38(4):917–932.
- [97] Qu L, Hu J, Li L, Zhang Y. PPCA-Based missing data imputation for traffic flow volume: A systematical approach. IEEE Trans. on Intelligent Transportation Systems, 2009,10(3):512–522.
- [98] Chen C, Wang Y, Li L, Hu J, Zhang Z. The retrieval of intra-day trend and its influence on traffic prediction. Transportation Research Part C: Emerging Technologies, 2012,22(5):103–118.
- [99] Tan H, Feng G, Feng J, Wang W, Zhang YJ, Li F. A tensor-based method for missing traffic data completion. Transportation Research Part C: Emerging Technologies, 2013,28:15–27.
- [100] Chang EP, Wang SH. Improved Freeway Incident Detection using Fuzzy Set Theory. 1994. 75–82.
- [101] Stephanedes YJ, Liu X. Artificial neural networks for freeway incident detection. In: Proc. of the Transportation Research Record. 1995.
- [102] Athanasios V, Nikolaos D, Anastasios D, Eftychios P. Deep learning for computer vision: A brief review. Computational Intelligence and Neuroscience, 2018,2018:1–13.
- [103] Yu D, Deng L. Automatic Speech Recognition: A Deep Learning Approach. Springer-Verlag, 2014.
- [104] Xue-Feng Xi, Guo-Dong Z. A survey on deep learning for natural language processing. Acta Automatica Sinica, 2016 (in Chinese with English abstract).
- [105] Marlin BM, Swersky K, Bo C, Freitas ND. Inductive principles for restricted Boltzmann machine learning. Journal of Machine Learning Research—Proc. Track for Artificial Intelligence and Statistics, 2010,9(9):509–516.
- [106] Shi X, Chen Z, Wang H, Yeung DY, Wong WK, Woo WC. Convolutional LSTM network: A machine learning approach for precipitation nowcasting. In: Proc. of the Int'l Conf. on Neural Information Processing Systems. 2015.
- [107] Yuan Z, Zhou X, Yang T. Hetero-ConvLSTM: A deep learning approach to traffic accident prediction on heterogeneous spatio-temporal data. In: Proc. of the 24th ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining. 2018. 984–992. [doi: 10.1145/3219819.3219922]

附中文参考文献:

- [78] 王飞跃,段艳杰,吕宜生,等.一种基于 lstm 的路段行程时间预测方法.专利 CN106096767A,2016.



柏梦婷(1999—),女,学士,主要研究领域为机器学习,深度学习在智能交通领域的应用。



马萌(1986—),男,博士,副研究员,CCF 专业会员,主要研究领域为物联网,智能感知计算,复杂事件处理。



林杨欣(1992—),男,学士,主要研究领域为智能交通系统。



王平(1961—),男,博士,教授,博士生导师,CCF 专业会员,主要研究领域为网络安全,智能计算与感知,操作系统与中间件。