

高速公路施工场景下的交通流预测模型研究与应用

李钢

广东路路通有限公司 广东广州 510100

DOI: 10.32629/ems.v8i2.18520

[摘要] 随着高速公路养护施工活动的增多,施工区段对交通流的影响日益突出,导致通行能力下降和拥堵风险增加^[1]。为了实现施工场景下交通流量的准确预测,本文提出了一种基于 CNN-BiLSTM 混合深度神经网络的交通流预测系统,并设计了相应的云-边协同计算架构。系统首先通过多源传感器(如毫米波雷达和 ETC 门架)实时采集施工区上下游的交通数据,然后对数据进行清洗、插补和归一化预处理^[2]。在此基础上,构建卷积神经网络(CNN)与双向长期记忆网络(BiLSTM)融合的预测模型,CNN 负责提取交通流的空间局部特征,BiLSTM 捕获双向时间依赖信息^[4]。采用小批量随机梯度下降和 Adam 优化算法训练模型,并通过交叉验证调整超参数。实验使用高架高速公路仿真数据,在训练集和测试集上评估模型性能。结果表明,所提系统能有效预测施工区交通流变化趋势,预测值与实测值高度吻合,各项误差指标明显优于传统方法。最后讨论了模型的局限性及未来改进方向。

[关键词] 交通流预测;深度学习;CNN-BiLSTM;云边协同;高速公路施工

引言

近年来,城市道路和高速公路拥堵问题日趋严重,对交通运输安全和效率构成挑战^[2]。交通流预测作为交通控制和诱导策略的基础,能够通过实时数据滚动预测未来交通状况,在缓解拥堵中发挥重要作用^[2]。传统预测方法多采用时间序列和统计模型(如 ARIMA),简单易用但难以反映交通流量的非线性波动²。随着机器学习和深度学习技术的发展,越来越多研究采用神经网络进行交通流预测,其中双向 LSTM (BiLSTM) 在高速公路流量预测中表现出良好的时序泛化能力。

高速公路施工区(如养护施工、改扩建)往往导致路段通行能力下降,从而引发交通流状态突变和瓶颈形成。文献研究表明,高速公路施工区的过渡车道是流量瓶颈,当车流密度超过 30 辆/km 时,流量状态会发生突变。因此,在施工场景下开展交通流预测,对施工诱导、交通组织和安全管控具有重要意义。为此,本研究提出基于深度神经网络的预测

系统,将道路交通仿真与深度学习相结合,在施工环境中验证模型效果。最近有学者提出将 CNN 与 BiLSTM 结合的混合模型用于交通流预测,该模型利用 CNN 提取输入特征的空间隐藏信息,BiLSTM 理解时间上下文,取得了优于单一模型的预测精度。此外,智慧高速道路系统强调云-边协同计算,边缘侧进行实时感知与初步决策,云端负责全网模型训练与协调^[5]。例如,雷达+ETC 感知方案实现全天候交通态势监测,并通过数字孪生架构将感知、计算、仿真贯穿云-边-端全链路^[6]。基于以上背景,本文研究内容如下:设计 CNN-BiLSTM 时空预测模型并说明其训练方法;提出云边协同的系统集成架构及数据采集方案;通过仿真实验分析模型在高速公路场景下的预测效果及误差表现;最后总结研究结论并展望未来方向。

1 技术路线

本系统的总体技术路线如图 1 所示:

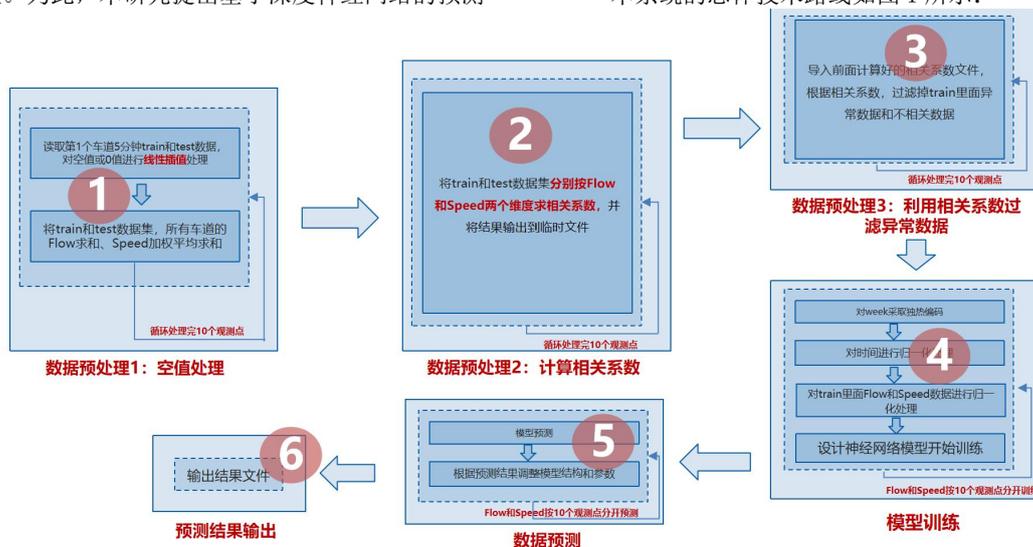


图 1 总体技术路线图

包括以下关键步骤:

(1) 数据采集: 在施工路段及其上下游部署多源感知设备,包括毫米波雷达和 ETC 门架等,实时采集车辆流量、速

度、占有率等数据。同时,可接入天气、事故等外部信息作为辅助数据。

(2) 数据预处理: 对采集到的原始交通数据进行清洗、

缺失值插补和通过相关系数消除异常数据 (如图 2: 异常数据
处理前, 如图 3: 异常数据处理后), 并对 week 进行独热
编码 (如图 4: 独热编码前的数据、图 5: 独热编码后的数据),
消除对后面模型训练的误导。预处理保证数据质量和一致性,
为模型训练提供可靠输入。

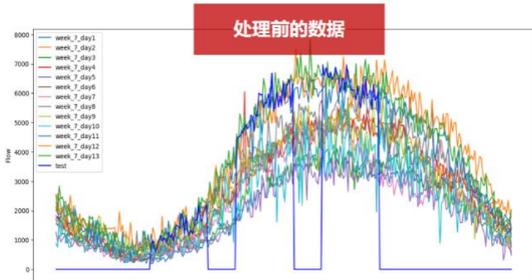


图 2 异常数据处理前

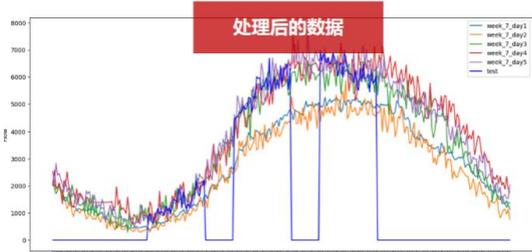


图 3 异常数据处理后

Week_1_0	Week_2_0	Week_3_0	Week_4_0	Week_5_0	Week_6_0	Week_7_0
1	0	0	0	0	0	0
0	1	0	0	0	0	0
0	0	1	0	0	0	0
0	0	0	1	0	0	0
0	0	0	0	1	0	0
0	0	0	0	0	1	0
0	0	0	0	0	0	1

图 4 独热编码前的数据

Time	Lane 1 Flow (Veh/h)	Lane 2 Flow (Veh/h)	Lane 3 Flow (Veh/h)	Lane 4 Flow (Veh/h)	Lane 1 Speed (km/h)	Lane 2 Speed (km/h)	Lane 3 Speed (km/h)	Lane 4 Speed (km/h)	Week
23.15	308	572	584	305	117.73	109.7	113.29	108.49	7
23.20	304	509	538	321	120.51	105.73	112.53	109.78	7
23.25	257	536	568	240	110.26	109.13	107.84	105.6	7
23.30	267	530	525	247	119.74	112.07	109.25	103.08	7
23.35	314	585	604	246	117.55	110.51	106.39	106.07	7
23.40	253	452	444	241	117.49	110.24	104.9	106.88	7
23.45	262	530	573	238	110.72	106.2	103.32	106.25	7
23.50	294	550	616	247	117.55	110.51	106.39	106.07	7
23.55	165	355	465	165	106.17	100.26	100.26	100.26	1
0.00	159	355	305	238	110.72	106.2	103.32	106.25	7
0.05	252	443	487	271	118.33	108.69	108.49	106.68	1
0.10	220	449	392	251	120.32	113.26	108.32	98.39	1
0.15	183	361	507	178	119.18	104.72	114.53	102.36	1
0.20	158	364	308	173	119.04	113.07	103.45	106.62	1
0.25	180	344	343	252	117.7	107.25	106.41	100	1
0.30	165	331	317	144	124.06	110.35	106.04	102.66	1

图 5 独热编码后的数据

(3) 模型训练与预测: 构建 CNN-BiLSTM 融合预测模型, 利用上述预处理数据进行训练。模型训练采用带小批量 (mini-batch) 的随机梯度下降算法和 Adam 优化器, 通过交叉验证调节窗口长度和网络层数等超参数以获得最佳结构。训练完成后, 可在实时数据或测试集上运行模型进行交通流预测。

(4) 系统集成与部署: 设计云-边协同的系统架构。在边缘层部署预测模型实例对施工区数据进行实时分析, 并在云端进行模型管理和全局计算协调。同时建立可视化界面, 将预测结果用于施工诱导和交通管控。系统还需实现预测结果和原始数据的存储与共享, 以持续迭代优化模型。

2 模型构建

为充分捕获交通流的时空特性, 本文采用卷积神经网络 (CNN) 与双向长短期记忆网络 (BiLSTM) 相结合的混合模型。模型结构的输入层接收多断面时序交通流量数据, 先经过一维卷积层和池化层提取空间局部特征, 后接单层 BiLSTM 提取时间序列的前后依赖信息。具体地, CNN 层通过 Conv1D 和 MaxPooling1D 层堆叠实现, 目的是捕捉相邻交通断面间的空间相关性; BiLSTM 层对输入序列进行正、反两方向的遍历, 使模型能够综合利用历史和未来时刻的信息。CNN 层和 BiLSTM 层末尾各接 Dropout 层, 以随机丢弃部分神经元减轻过拟合。关键代码如图 6 所示:

```

model_cnn_BiLSTM_5 = Sequential()
model_cnn_BiLSTM_5.add(Conv1D(filters=64, kernel_size=5, activation='relu', input_shape=(24, 12, 9)))
model_cnn_BiLSTM_5.add(MaxPooling1D(pool_size=2, activation='relu'))
model_cnn_BiLSTM_5.add(Flatten())
model_cnn_BiLSTM_5.add(Dense(256, activation='sigmoid'))
model_cnn_BiLSTM_5.add(Dense(128, activation='tanh', return_sequences=True))
model_cnn_BiLSTM_5.add(Dense(128, activation='tanh'))
model_cnn_BiLSTM_5.add(Dense(12, activation='sigmoid'))
model_cnn_BiLSTM_5.compile(loss='MAE', optimizer='adam')
    
```

图 6 模型构建的关键代码

输入数据首先在预处理后送入模型。预处理步骤包括: 使用最大-最小归一化将流量数据映射到 [0, 1] 区间, 并采用均值插值填补传感器故障等造成的缺失值。例如, 对交通流量 x_i 应用归一化为 $\hat{x}_i = (x_i - x_{min}) / (x_{max} - x_{min})$ 。缺失数据则通过相邻时间点数据的平均值进行简单插补。这样处理后, 输入 CNN 层的数据保证了量纲一致, 有利于模型学习稳定性。

模型训练过程中, 采用基于均方差 (MSE) 的损失函数, 并使用 Adam 优化器进行参数更新。为评价模型性能, 选用均方根误差 (RMSE)、平均绝对误差 (MAE)、平均绝对百分比误差 (MAPE) 和拟合度 R2 等指标。

通过对比实验发现, 本文模型在 5 项指标上均明显优于单独的 LSTM/GRU 模型及传统 ML 模型。超参数方面, 经实验确定滑动窗口长度为 20 分钟 (4 个 5min 时段), CNN 层和 BiLSTM 层各使用 1 层结构, 卷积核深度 64, BiLSTM 隐藏单元 512, Dropout 比率 0.1。在上述配置下, 模型取得了较小的预测偏差和较高的准确率。

3 系统集成架构

本预测系统采用端-边-云三级架构, 实现传感感知、边缘分析和云端协同。

感知层部署高速公路施工区相关传感器: 地磁或线圈检测器用于车辆计数, 视频摄像头和雷达用于速度和异常事件识别, ETC 门架用于通过车辆统计。这些设备从不同角度实时采集交通流量、车速等多源数据, 为预测提供信息基础。文献指出, 在高速场景中毫米波雷达+ETC 方案可以实现全路段全时段的高精度交通感知, 克服了传统摄像头夜间或恶劣天气下的不足。

边缘计算层位于现场路侧设备或施工区控制中心, 用于快速预处理和近实时预测。边缘计算节点对采集到的数据进行去噪、压缩并运行 CNN-BiLSTM 模型进行初步预测, 及时反馈局部交通态势。这有助于降低对中心云带宽和计算资源的依赖。根据云控平台标准, 边缘云可执行分布式数据缓存和初步分析, 将重点数据异步上传至云端。中心云收到来自各施工路段的预测结果和原始数据后, 可进行更大范围的协调

分析和历史数据存储。

云计算部署在交通管理部门的数据中心或云平台上,负责模型的统一训练、全网数据管理和决策支撑。中心云具有跨区域管理能力,负责调度各边缘云资源、数据同步和安全管控。在云端还可建立交通数字孪生平台,将实时监测到的高速公路状况映射到仿真模型进行进一步预测和优化。云-边协同架构确保了施工场景下交通流数据的快速汇聚与处理,支持高频低时延的预测应用。总体而言,该系统逻辑架构自底向上可分为感知层、边缘层、云平台层和应用层,以实现从数据获取到预测决策的全流程协同。

4 实例分析

为验证模型的有效性,本文设计了高速公路交通流预测实验。实验采用连续交通流数据,选取某高速公路数据集作为参考,采集数据的道路检测器的部署如下图 7 所示。

共 10 个检测器,其中检测器间距为 500 米到 1500 米不等。道路为单向四车道,运行方向为从 1 往 10。

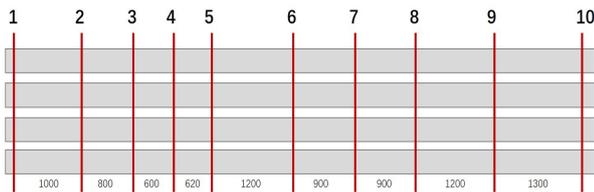


图 7 道路检测器

Train-30s, Test-30s 数据集为 Train-5min, Test-5min 原始数据,检测时间间隔为 30s,其中流量单位为 Veh,表示 30s 内通过检测器的车辆数;速度单位为 mph。

使用测试集数据,对测试集各天 8:00-8:55、12:30-13:25、17:00-17:55 的所有检测器的流量和速度进行预测。预测结果按照检测器 1 到检测器 10 分布,每个检测器需要预测流量和速度。预测流量为四车道相加值,保留整数,速度为每车道流量加权平均,保留两位小数。

流量和速度计算公式如下所示:

$$Flow = \sum_{l=1}^L flow_l$$

$$Speed = \sum_{l=1}^L \frac{flow_l \times speed_l}{Flow}$$

其中 l 为单一车道;flow 为单一车道流量;speed 为单一车道速度。

测试误差评价指标及计算方法如下所示:

$$Score = \frac{\sum_{p=1}^P \sum_{t=1}^T \sum_{l=1}^L \frac{MAE_{ptl} + RMSE_{ptl}}{Aver_{ptl}}}{P \times T \times L}$$

其中 p 为选定的预测变量,即流量和速度;t 为需要预测的时间段,即测试集中 7 天共 21 个时间段;l 为选用的 10 个检测器。Aver、MAE、RMSE 的计算公式如下所示:

$$Aver = \frac{1}{m} \sum_{i=1}^m y_i$$

$$MAE = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i|$$

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2}$$

其中 m 为数据数量, y_i 为真实值, y_i 为预测值。

实验预测结果如图 8 所示:

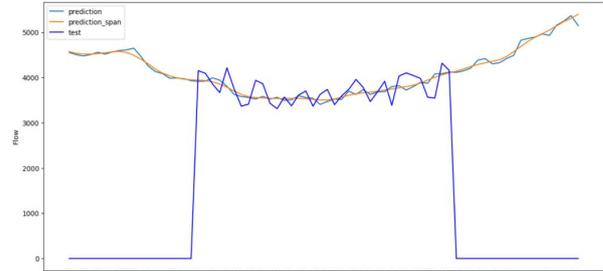


图 8 预测结果

结果表针对交通流量序列存在的时空相关性等特征,结合 CNN 与 BiLSTM 各自优点的交通流预测模型。通过 CNN 和 BiLSTM 分别提取空间和时间特征。通过实例验证分析表明:相比于其他基准模型,该预测模型能够较好地适应不断波动的交通流量数据。

5 结论与展望

针对高速公路施工场景下交通流预测需求,本文提出了基于 CNN-BiLSTM 的时空融合预测模型,并构建了云-边协同的系统架构。该模型通过 CNN 和 BiLSTM 分别提取空间和时间特征,在模拟实验中对施工区交通流的短期预测取得了较高精度。实验结果验证了模型预测稳定性和整体误差优势,相比传统方法表现更优。系统集成方案中,通过多传感器数据采集与边缘计算,实现了施工区交通信息的实时感知和快速处理。然而,研究仍有提升空间:未来可引入注意力机制增强模型对关键特征的关注,利用更多外部因素(如天气、事故)进一步优化预测。同时,可在更多真实施工项目中验证系统的实用性,并探索与诱导控制方案的深度耦合。总之,本研究为智慧高速公路施工管理提供了一种有效的预测工具,对提升施工区的交通组织水平和安全保障具有实际意义。

【参考文献】

- [1] 邵长桥, 黄群龙. 高速公路改扩建施工区交通流特性[J]. 北京工业大学学报, 2020, 42 (4): 737-745.
- [2] 刘永乐, 谷远利. 基于 CNN-BiLSTM 的高速公路交通流量时空特性预测[J]. 交通科技与经济, 2022 (1): 87-94.
- [3] 关振翔, 孙红岩, 董雨晴, 田丰, 李金为. 大数据分析在智能交通流量预测与管理中的应用[J]. 科技理论与实践, 2025, 6 (2): 79-85.
- [4] Manuel Méndez, Mercedes G. Merayo, Manuel Núñez. Long-term traffic flow forecasting using a hybrid CNN-BiLSTM model[J]. Engineering Applications of Artificial Intelligence, 2023, DOI: 10.1016/j.engappai. 2023. 106041.
- [5] 中国智能交通产业联盟. 智慧高速公路云控平台总体技术要求[S]. 2022.
- [6] 曾祥平. 基于“Radar+ETC”实时感知的高速公路数字底图技术的应用和经验[J/OL]. 搜狐, 2021-12-14.