

# 基于SA-DL模型的高速公路交通流预测方法研究

杨存祥

(聊城市阳谷县交通运输局, 山东 聊城 252300)

**摘要** 本文综合考虑空间依赖关系、天气和时空因素对高速公路交通流变化的影响, 提出考虑多因素特征的高速公路交通流预测模型。利用可以全局处理信息序列和动态生成权重的自注意力机制(Self-Attention, SA)捕获高速公路交通流空间依赖关系, 提高交通流空间特征提取能力; 利用卷积神经网络(Convolutional Neural Networks, CNN)和长短时记忆(Long Short-Term Memory, LSTM)模型提取交通流空间特征、趋势性特征和周期性特征, 通过分析高速公路交通流特征, 对未来交通流进行预测。研究表明, SA-DL模型对于工作日和节假日高速公路交通流预测结果精度优于ARIMA模型, SA-DL模型工作日交通流预测MAE均值为 $7.38(15\text{min})^{-1}$ , RMSE平均值为 $9.58(15\text{min})^{-1}$ ; 节假日交通流预测MAE均值为 $7.38(15\text{min})^{-1}$ , RMSE平均值为 $9.58(15\text{min})^{-1}$ 。

**关键词** 高速公路; 自注意力机制; 交通流预测; 深度学习

中图分类号: U412; TP3

文献标识码: A

文章编号: 1007-0745(2023)09-0010-04

随着社会经济的飞速发展和城镇人口的快速增长, 机动车数量呈逐年上升趋势, 由此引发的道路交通拥挤问题日益严峻, 尤其是高速公路的拥挤问题, 已成为一个国家亟待解决的问题。作为一个国家迈向现代化的重要纽带, 高速公路是发展现代交通运输业的重要道路<sup>[1]</sup>。然而, 在高速公路上出现的交通拥挤问题, 不但给人民的生活造成了很大的不便, 而且还限制了高速公路的服务品质, 对地区的经济和社会发展产生了一定的影响。因此对高速公路交通流的预测, 不但能够帮助高速公路的管理者进行科学的调度和引导, 还能够帮助人们选择最佳的出行路径, 对缓解高速公路段的拥堵问题具有重要的理论和现实意义。

## 1 SA-DL模型建立

### 1.1 模型架构设计

基于自注意力机制和深度学习(Self-Attention-DeepLearning, SA-DL)的高速公路交通流预测模型是一种在考虑多因素的预测方法, 其利用自注意力模型捕获高速公路交通流数据的全局空间管关系, 提高交通流特征提取能力<sup>[2]</sup>。SA-DL模型包括数据处理、特征矩阵构建、卷积神经网络CNN和LSTM。

SA-DL模型首先对交通数据进行缺失值填补、关系型数据选取等预处理; 其次建立包含天气特征和时间特征的二维特征矩阵, 然后利用CNN技术从矩阵中获取交通流空间特征, 提取全局空间依赖关系; 最优利

用LSTM提取交通流时间特征, 通过全连接层, 获得交通流预测输出结果<sup>[3]</sup>。

### 1.2 数据预处理

由于获取的高速公路交通流数据存在数据少量缺失的情况, 为保证数据预测精度, 选取近三年的同一天和同一时间测量传感器数据的平均值, 然后将数据填充到空缺位置, 以此来补全缺失数据<sup>[4]</sup>。

为降低外界因素对高速公路预测结果的影响, 采用皮尔逊相关分析法计算目标道路交通流和不同属性的相关系数, 然后根据系数大小选取与高速公路交通流相关性强的特征数据<sup>[5]</sup>。数据相关系数绝对值越大, 其与高速公路交通流的相关性越强; 相关系数绝对值越小, 其与高速公路交通流的相关性越弱。

### 1.3 特征矩阵构建

高速公路交通流与道路交通流量和天气变化相关, 因此建立包括天气信息、空间信息和时间信息的二维特征矩阵, 利用矩阵获取高速公路交通流特征数据。 $t$ 时刻高速公路交通流量为 $\{x_{s, t}, x_{s2, t}, \dots, x_{sm, t}\}$ ;  $t$ 时刻天气数据为 $\{w_{q1, t}, w_{q2, t}, \dots, w_{qn, t}\}$ 。

### 1.4 自注意力模型

对于可变长度向量序列, 一般采用循环网络和卷积网络两种方式对其进行编码, 从而得到等长输出向量序列<sup>[6]</sup>。如在图1中所示, 图(a)采用卷积网络对可边长度向量序列进行编码, 图(b)采用循环神经

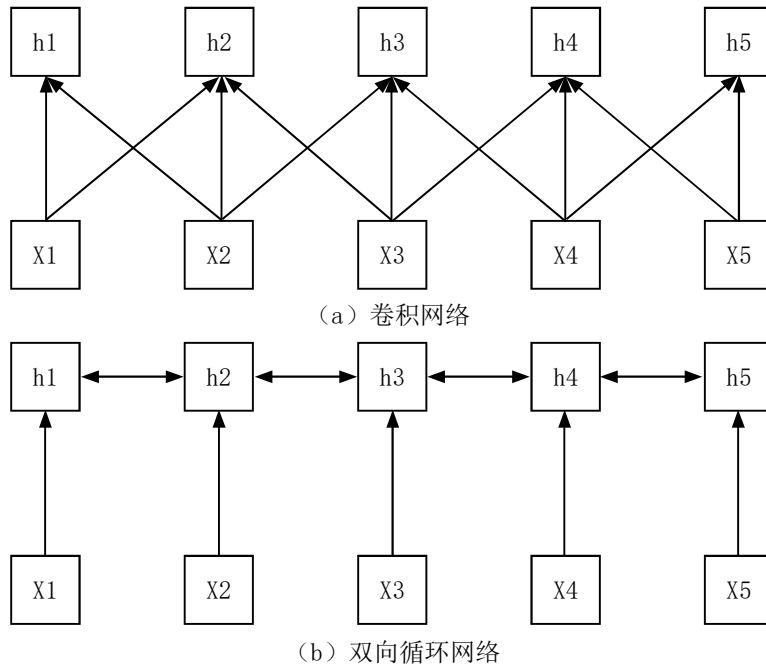


图 1 循环网络和卷积网络的边长序列编码

络对可边长度向量序列进行编码。

从图 1 中可以看出, 循环神经网络和卷积神经网络均只能对可变长度序列进行“局部编码”。卷积神经网络是一个以 N-Gram 为基础的局部编码。该算法的基本思路是以字节数表示为 N 个滑动窗, 然后生成一系列 N 个字节的片段序列。每一位字节片段都为 gram。该算法计算了所有 gram 的出现次数, 然后按照预先设定的阈值对 gram 进行筛选, 得到一个关键词清单, 而清单中的 gram 类型就是一个特征矢量的一个维度。该模型得出的相邻关键词均有相关性, 整个句子出现的概率为所有关键词出现概率的乘积。

循环神经网络存在梯度消失问题, 其只可以建立短期依赖, 而在长距离依赖关系方面, 则需要通过增加网络层数和使用全连接网络等方式进行建立。

自注意力机制有利于减少交通流预测对外部信息的依赖, 以此来更好地捕获高速公路交通流数据以及特征内在相关性。假设高速公路交通流预测时的输入信息为  $H=[h_1, h_2, \dots, h_n]$ , 利用自注意力机制获得的位置输出为  $Y=[y_1, y_2, \dots, y_n]$ 。

首先, 将原始输入数据映射到值空间 V、键空间 K 和查询空间 Q, 计算公式如下:

$$Q=HW_q=[q_1, q_2, \dots, q_n]$$

$$K=HW_k=[k_1, k_2, \dots, k_n]$$

$$V=HW_v=[v_1, v_2, \dots, v_n]$$

然后计算每个位置注意力分布情况, 并对计算结

果加权求和:

$$y_i = \sum_{j=1}^n \text{softmax}(s(q_i, k_j)) v_j$$

为进一步加快计算效率, 利用矩阵计算出多有位置输出向量:

$$Y = \text{softmax}(QK^T / \sqrt{D_k}) V$$

将构建的特征矩阵进行一维卷积后导入 self-attention 中, 对相邻道路的天气特征和交通流特征进行连接, 并计算注意力分布情况, 捕获交通流依赖特征。

## 2 实验分析

考虑到高速公路节假日和工作日的交通流存在较大差距, 因此分别对节假日和工作日的交通流进行预测和训练; 为验证 SA-DL 模型的预测精度, 与 ARIMA 模型进行对比分析, ARIMA 模型是以时间为基础, 将预测对象随时间变化所形成的数据序列作为随机序列, 然后利用数学模型来描述该序列, 进而从时间序列的过去值及现在值预测未来值。

### 2.1 数据来源及预处理

数据集来源于某高速公路交通天气数据和流数据, 该高速公路共有 3 个收费站, 其中 2 号收费站为单向行驶路段, 只允许车辆进入高速路段。1 和 3 号路段为双向行驶路段。

高速公路交通流和天气数据采集数据时间范围为 2021 年 9 月 20 日 -2020 年 10 月 18 日, 采集频率为每隔 20min 采集一次数据。天气数据特征包括风向、气压、

表1 对10d工作日的预测误差

	MAE/(辆·(15min) <sup>-1</sup> )	RMSE/(辆(15min) <sup>-1</sup> )
1	4.51	7.30
2	5.61	8.66
3	7.72	10.31
4	7.70	10.89
5	7.73	11.21
6	8.26	11.30
7	12.31	10.22
8	7.30	9.25
9	6.24	7.37
10	6.41	9.30
平均	7.38	9.58




图2 模型MAE和RMSE对比结果

温度、降雨量、风速、湿度、降雨量等，采集频率为3h采集一次。

## 2.2 工作日交通流预测

表1所示SA-DL模型预测高速公路交通流工作日10d数据的均方根误差(RMSE)和平均绝对误差(MAE)。

从表1中可以看出，对高速公路工作日10d交通流预测结果的MAE均值为 $7.38(15\text{min})^{-1}$ ，RMSE平均值为 $9.58(15\text{min})^{-1}$ 。

为验证提出SA-DL模型预测性能，利用ARIMA模型对原始数据进行分析和处理，测试结果如图2所示。

从图2中可以看出，SA-DL模型对高速公路交通流的预测结果RMSE和MAE均低于ARIMA模型。与RMSE模型相比，SA-DL模型的RMSE和MAE分别下降了29.69与27.93。

## 2.3 节假日交通流预测

表2所示SA-DL模型预测高速公路交通流节假日10d数据的RMSE和MAE。

从表2中可以看出，SA-DL对高速公路节假日10d交通流的预测结果的MAE平均值为 $6.62(15\text{min})^{-1}$ ，RMSE平均值为 $8.39(15\text{min})^{-1}$ 。

图3所示SA-DL模型与ARIMA模型预测结果对比情况，从图3中可以看出，SA-DL模型预测结果明显低于ARIMA模型预测结果。SA-DL模型的RMSE和MAE分别下降了19.15和15.73。

由此可见，对于节假日和工作日道路交通流量的预测结果，SA-DL预测结果更加准确，SA-DL模型对高速公路交通流预测结果误差均值较低，可以为交通管理提供参考。

表 2 10 天节假日的预测误差

	MAE/(辆·(15min) <sup>-1</sup> )	RMSE/(辆(15min) <sup>-1</sup> )
1	5.42	8.13
2	6.62	8.39
3	5.39	7.81
4	8.19	10.81
5	3.33	6.54
6	5.32	7.23
7	9.54	10.30
8	6.51	7.30
9	5.63	8.41
10	6.42	8.61
平均	6.62	8.39

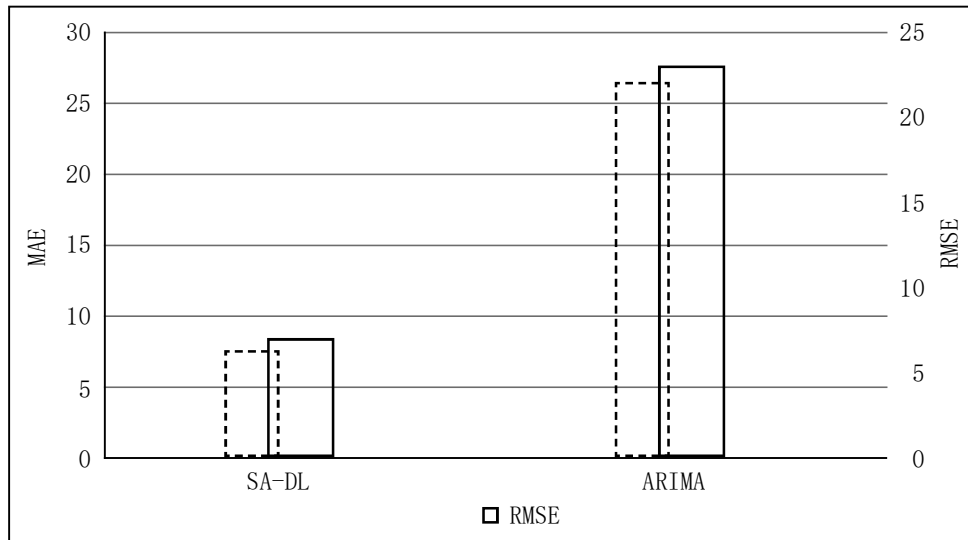


图 3 模型 MAE 和 RMSE 对比结果

### 3 结论

基于深度学习和自注意力机制的预测模型,采用自注意力机制捕获高速公路交通流空间依赖关系,进一步提高交通流空间特征提取能力;采用 LSTM 解决时序依赖性问题,提取数据趋势性和周期性特征。对于高速公路节假日和工作日交通流量的预测,SA-DL 模型预测结果精度明显优于 ARIMA 模型,并且与实际观测结果基本一致。将天气特征和时空特征引入交通流预测过程中,利用自注意力机制特征关键信息,捕获全局依赖关系,可以进一步提高预测结果的准确性。

### 参考文献:

[1] 秦畅. 基于自注意力机制的时空网络交通流预测研

究[J]. 电脑编程技巧与维护,2023(06):167-169.

[2] 何鸿杰,陈先龙. 基于指数平滑法和残差网络的短时交通流预测方法[J]. 交通工程,2023,23(03):97-106.

[3] 王静潇,王辛岩,周禹彤,等. 面向交通流预测的分支定界算法图卷积模型[J]. 现代电子技术,2023,46(12):153-158.

[4] 刘志,陈洋,周涵林,等. 基于时空动态循环图卷积网络的交通流预测[J]. 浙江工业大学学报,2023,51(03):282-288.

[5] 谭美芳,匡锐,张清勇,等. 基于改进灰狼算法优化 LSTM 的断面交通流预测[J]. 武汉理工大学学报,2023,45(05):132-139.

[6] 邴其春,张伟健,沈富鑫,等. 基于变分模态分解和 LSTM 的短时交通流预测[J]. 重庆理工大学学报(自然科学),2023,37(05):169-177.