

DOI:10.11918/202407040

基于时空关联和异构图卷积的车道级流量预测

罗义凯,徐金华,李昱燃,刘成昊,李岩

(长安大学 运输工程学院,西安 710064)

摘要:为细化交通流量预测的空间粒度,解决传统方法忽略车道差异作用机理带来的局限性,以车道为研究对象,提出了一种精准实时的车道级交通流量预测方法,考虑车道位置导致的流量时序特征差异性,以软-动态时间规整作为度量方法,利用 k 均值聚类算法对车道断面进行分类,分析各类型车道流量时序特征;引入逐步变分模态分解降低序列波动性,去除噪声干扰,将得到的分量作为预测模型的输入,融入斯皮尔曼相关性分析获取车道相关性关系;在双向门控循环单元嵌入多头自注意力机制,结合车道间距和车道相关性的双重边关系构建异构时空图卷积循环神经网络模型对各类车道流量进行预测。应用山西省某高速公路一个月流量数据进行测试,结果表明:所选区域车道类型分为4类最佳,分别为密集型车道、稀疏型车道、早高峰型车道和晚高峰型车道;对所有车道分别进行流量预测,与自回归移动平均、长短时记忆网络以及时空图卷积神经网络等模型相比,5 min 时间粒度下,所提模型的平均绝对误差和均方根误差分别降低了 11.21%~24.05%、8.89%~24.43%,决定系数可达 0.962;车道分类后的预测精度进一步提升;当 15 min 粒度下步长为 12 以内预测时,所提模型平均绝对误差和均方根误差最高增加了 15.82% 和 11.99%。研究成果可为道路规划和智能交通的发展提供依据。

关键词:车道级流量预测;异构图卷积循环神经网络;车道分类;软-动态时间规整;多头注意力机制

中图分类号:U491.1+4

文献标志码:A

文章编号:0367-6234(2025)11-0062-09

Lane-level traffic flow prediction based on spatiotemporal correlation and heterogeneous graph convolution

LUO Yikai, XU Jinhua, LI Yuran, LIU Chenghao, LI Yan

(School of Transportation Engineering, Chang'an University, Xi'an 710064, China)

Abstract: A lane-level traffic flow prediction method was proposed to refine the spatial granularity of traffic flow prediction and address the limitations in traditional prediction methods which overlooked the interaction mechanisms brought by the lane differences. The soft-dynamic time warping was chosen as the measurement method to consider the variations in traffic flow time series caused by the lane positions. Then, the k -means algorithm was aggregated in the proposed algorithm to classify the lane cross-sections, which was utilized to analyze the temporal characteristics of flow at the selected lane cross-section type. The sequential variational mode decomposition was introduced to reduce the volatility of time series flow data and remove its noise, whose results can serve as inputs for the prediction model. Based on the previous results, the lane correlations can be determined by incorporating the Spearman correlation analysis in the proposed method. The heterogeneous spatiotemporal graph convolutional recurrent neural network model for predicting the flow of various lane types can be established by embedding the multi-head attention mechanism into the bidirectional gated recurrent unit and combining the lane correlations and their distance. The traffic count data from several freeways in Shanxi, China was selected to assess the effectiveness of the proposed method. The results indicate that the freeway's lanes within the selected area can be classified to four categories: dense type, sparse type, morning peak type, and evening peak type, respectively. Compared to the autoregressive integrated moving average model, long-short term memory network model, and spatio-temporal graph convolutional network models, the proposed model reduces the mean absolute error and root mean square error by 11.21%–24.05% and 8.89%–24.43%, with the r -squared coefficient as 0.962 at the 5-minute granularity flow prediction for all the lanes. This result indicates the accuracy of the flow prediction can be further improved by considering the lane classification. When the prediction was accomplished at the 5-minute granularity with the step size within 12, the mean absolute error and root mean square error of the proposed model increased by 15.82% and 11.99% at most. The findings provide a basis for road planning and the development of intelligent

收稿日期:2024-07-12;录用日期:2024-08-10;网络首发日期:2025-07-10

网络首发地址:https://link.cnki.net/urlid/23.1235.T.20250710.0940.002

基金项目:国家自然科学基金(72371035);陕西省自然科学基金基础研究计划(2020JM-237)

作者简介:罗义凯(1998—),男,博士研究生;李岩(1983—),男,博士,教授,博士生导师

通信作者:李岩,lyan@chd.edu.cn

transportation.

Keywords: lane-level traffic prediction; heterogeneous graph convolutional recurrent neural network; lane classification; soft-dynamic time warping; multi-head attention mechanism

自动驾驶和车道级地图导航等技术的发展正在深刻影响着现代交通的运行模式^[1-2]。然而,面向整体道路的交通流量预测难以满足多样化场景和高精度需求^[3],因此亟需开展车道级粒度的交通流预测研究,以满足新兴技术的需求,并提高交通系统的精细化管理水平。

道路流量短时预测方法主要有基于统计的方法、机器学习的方法和深度学习等方法^[4-6]。基于统计的方法有时间序列分析、回归分析和指数平滑法等,其简单直观,适合数据量较少和关系简单的场景,但在处理复杂非线性关系和高维数据时存在一定局限。机器学习方法包括支持向量回归和决策树及其扩展等^[7-9],此类方法能利用历史数据提取交通流量模式,并应用学习模型预测^[10]。深度学习方法有长短期记忆网络(long short term memory, LSTM)、门控循环单元(gated recurrent unit, GRU)和时间卷积网络(temporal convolutional network, TCN)等,这类方法能更有效挖掘深层时空信息,取得更高预测精度^[11-15], Zhao 等^[16]引入图卷积(graph convolution network, GCN)提出时间图卷积网络(temporal graph convolutional network, T-GCN),可同时提取路网中的空间依赖和交通流量序列的时间依赖,效果明显优于基准模型。

传统流量预测方法较少关注车道断面分类的影响^[17]。动态时间规整(dynamic time warping, DTW)是时序数据相似度的常用方法,然而其未考虑参考点和测试点间相位差的相对重要性,可能导致错误分类^[18]。软-动态时间规整算法(soft-dynamic time warping, Soft-DTW)引入了可微且平滑的度量方法,从时间复杂度和研究精度上比较算术法、DBA(dynamic time warping barycenter averaging)、DTW和 Soft-DTW,通过分析时间序列的质心构造,Soft-DTW 所用计算时间和平均距离均为最短^[19-20]。

车道级的交通流预测近年来逐渐受到关注, Ma 等^[21]通过建立高速公路车道上下游的关系,利用 LSTM 对车道流量进行预测; Ke 等^[22]提出了一种考虑交通流量影响的双重通道卷积神经网络模型用于高速公路多车道交通速度预测; Lu 等^[23]利用深度学习框架,对城市高架车道流量预测。上述方法多考虑不同时间间的动态相关性对未来交通流信息进行预测。然而,车道级流量预测是时空数据预测问题,不同位置和时间戳的观测数据动态相关。因

此,解决此问题的关键是有效地提取数据的时空相关性,除需考虑时间相关性外,还需关注车道间的空间影响,车道间距是常用的空间影响特征,但仅考虑车道间距的影响难以全面表征空间特征。此外,预测前对交通流数据的处理也直接影响着预测精度,赵阳阳等^[24]引入了经验模态分解(empirical mode decomposition, EMD)对数据预处理,可进一步提升预测精度。但 EMD 受噪声影响大,易出现模态混叠现象,即特定本征模态函数(intrinsic mode function, IMF)中包含多种不同的频率成分^[25]。

针对上述问题,本文考虑到车道特性及位置的差异性,断面的流量时序特征也会不同,据此对不同位置车道分类;并引入逐步变分模态分解对数据预处理;最后在此基础上,结合动态时间相关性、车道间距和车道相关性多重时空影响因素,构建异构时空图卷积循环神经网络对各个车道流量进行预测。

1 研究方法

图 1 展示了车道级流量的时空特性。其中,空间影响包含车道间距和车道相关性;在时间维度上,各车道截面不同时间戳的历史观测对未来流量的影响各异。

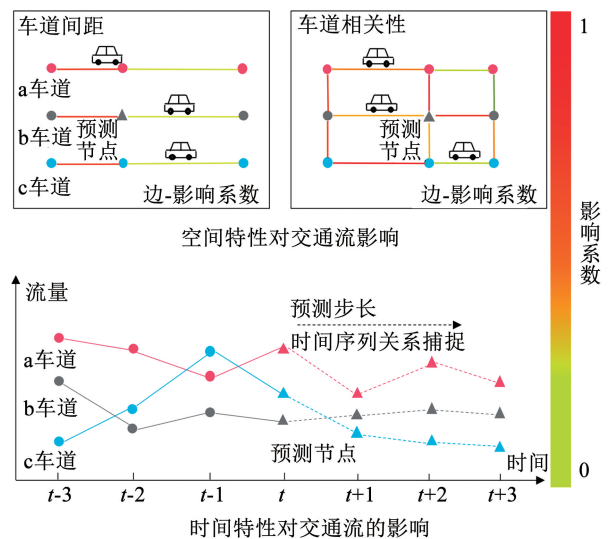


图 1 时空特性对车道级流量预测的影响

Fig. 1 Impacts of spatiotemporal characteristics on lane-level flow prediction

据此,可按以下步骤预测车道级交通流量:根据各车道不同位置的流量时序数据的差异,利用 Soft-DTW- k -means 算法对车道分类;考虑数据采集的干

扰,采用逐步变分模态分解(sequential variational mode decomposition, SVMD)处理输入数据^[25];引入多头注意力机制捕捉时序数据的动态时间相关性,并利用关系图卷积网络(relational graph convolutional network, R-GCN)提取车道间距和车道相关性的空间特征影响,结合双向门控循环单元(bidirectional gated recurrent unit, Bi-GRU)构建异构时空图卷积循环神经网络(relational heterogeneous spatio-temporal graph convolutional recurrent network, R-STGCN)预测车道级的流量。

1.1 Soft-DTW- k -means 车道聚类

Soft-DTW 在 DTW 基础上引入平滑惩罚参数,构建更平滑的质心,用于评价时间序列特征相似性。结合 k -means 算法,Soft-DTW- k -means 算法对车道聚类的步骤如下。

算法:Soft-DTW- k -means 车道聚类

输入:各车道流量时序数据

步骤:1)初始化 k -means 聚类的质心,质心也是一组流量序列;

2)使用 Soft-DTW 距离度量,计算每个车道时间序列与所有质心之间的距离,并将其分配到距离最小的质心所在的簇中;

3) while 簇分配不再变化 do;

4)重新计算每个簇的质心,质心计算方法使用 k -means 算法中的均值更新步骤,同时考虑 Soft-DTW 距离度量;

5)迭代更新模型;

6)end while

输出:车道聚类结果,每个簇为一类具有相似流量时序特征的车道。

上述步骤中,Soft-DTW 距离计算方式为

$$\text{SoftDTW}(\mathbf{X}_1, \mathbf{X}_2) = \min_{\Gamma} \text{DTW}(\mathbf{X}_1, \mathbf{X}_2, \Gamma) + \gamma R(\Gamma) \quad (1)$$

式中: $\mathbf{X}_1, \mathbf{X}_2$ 为两组时间序列; Γ 为对齐路径约束;DTW($\mathbf{X}_1, \mathbf{X}_2, \Gamma$) 为序列 $\mathbf{X}_1, \mathbf{X}_2$ 在对齐路径 Γ 下计算原始 DTW 距离; γ 为非负的平滑参数; $R(\Gamma)$ 为正则化项。

1.2 逐步变分模态分解

各车道流量时序序列具有较强的波动性,引入 SVMD 算法将车流量序列分解为有限固有模态分量,学习不同频率的序列特征以提高预测精度。SVMD 相比 EMD 有较低的计算复杂度和更高的鲁棒性,可自适应寻找最优模态个数 K 和惩罚因子 α ,可表示为如下带约束的优化问题:

$$\min_{u_k, w_k, f_r} \left\{ \xi \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega t} \right\|_2^2 + \right.$$

$$\left. \left\| \beta_k(t) * f_r(t) \right\|_2^2 + \sum_{i=1}^{k-1} \left\| \beta_i(t) * u_k(t) \right\|_2^2 \right\} \quad (2)$$

$$\text{s. t. } \begin{cases} f_{\text{signal}} = u_k(t) + f_r(t) \\ f_r(t) = \sum_{i=1}^{k-1} u_i(t) + f_u(t) \end{cases} \quad (3)$$

式中: u_k 为第 k 个分解单分量调幅调频信号; $f_r(t)$ 为剩余信号; $u_i(t)$ 为已分解的模态分量; $f_u(t)$ 为输入信号当中未处理部分; w_k 为第 k 个分解单分量调幅调频信号的中心频率;* 为卷积; ξ 为平衡系数; $\beta_k(t)$ 和 $\beta_i(t)$ 均为滤波器的脉动响应; f_{signal} 为原始信号。

1.3 R-GCN 异构图卷积

车道流量预测空间影响在考虑车道间距的基础上,同时考虑车道相关性,应用斯皮尔曼相关性对各车道断面的车流量时序序列进行相关性分析:

$$\rho = 1 - \frac{6 \sum e_i^2}{w(w^2 - 1)} \quad (4)$$

式中: ρ 为斯皮尔曼相关系数, e_i 为第 i 个数据对的位次差, w 为观测样本数。

针对双重空间边关系,引入 R-GCN 提取不同空间特征影响,更新车道断面节点自身流量表示。针对处理多关系数据存在对罕见关系过拟合的问题,采用基数分解法对 R-GCN 层规则化:

$$\mathbf{h}_i^{(l+1)} = \sigma \left(\sum_{r \in \mathbf{R}} \sum_{j \in N_i^r} \frac{1}{\mathbf{c}_{i,r}} \mathbf{M}_r^{(l)} \mathbf{h}_j^{(l)} + \mathbf{M}_0^{(l)} \mathbf{h}_i^{(l)} \right) \quad (5)$$

式中: $\mathbf{h}_i^{(l)}$ 为节点 i 的第 l 层节点表示; $\mathbf{h}_j^{(l)}$ 为节点 i 所有邻居节点的第 l 层节点表示; N_i^r 为节点 i 关系为 r 的邻居集合; $\mathbf{c}_{i,r}$ 为正则化向量,取值为 $|N_i^r|$; $\mathbf{M}_r^{(l)}$ 为线性转化函数,将同类型边的邻居节点,使用同一个参数矩阵转化; $\mathbf{M}_0^{(l)}$ 为与自身特征相关的权重矩阵; σ 为激活函数。

如图 2 所示,中心红色节点通过聚合邻居节点和自身信息来更新表示,邻居节点的聚合根据边的类型分类,并根据不同的边类型进行转换,收集的信息经正则化加和后通过激活函数 ReLU。

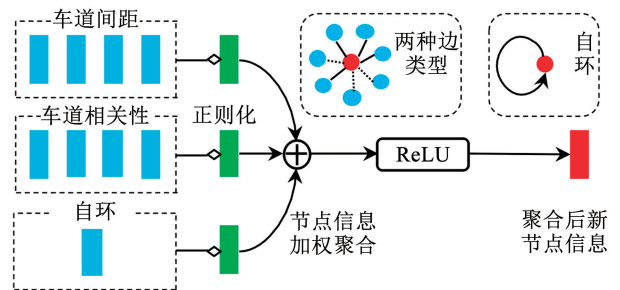


图 2 R-GCN 结合车道间距和车道相关性聚合更新节点信息
Fig. 2 Node information update in the R-GCN with considerations of lane distance and lane correlation

1.4 多头自注意力机制

由于不同时刻流量对预测性能的贡献有差异, 因此引入多头自注意力机制, 通过赋予各时间步差异化权重, 动态调整不同时刻流量数据对预测的影响, 在 Bi-GRU 层的基础上进一步提高预测精度。

多头自注意力机制通过使用多个独立注意力头, 分别计算注意力权重并将结果拼接, 每个注意力头都有查询 Q 、键 K 和值 V 向量, 通过线性变换将输入序列映射到不同表示空间, 计算 i 个注意头的分数值 H_i , 并将其输出拼接后与随机参数矩阵相乘, 生成注意力分数值:

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (6)$$

$$H_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V) \quad (7)$$

$$\text{MultiHead} = \text{Concat}(H_1, H_2, \dots, H_n)W^O \quad (8)$$

式中: W_i^Q 、 W_i^K 、 W_i^V 分别为 Q 、 K 、 V 投影到子空间的参数矩阵, W^O 为多头拼接后的参数矩阵。

1.5 RSTGCN 整体网络架构

RSTGCN 模型结构如图 3 所示, 运算流程如下。

步骤 1 设车道断面集 $A = \{a_1, a_2, \dots, a_m\}$, 包含 m 个车道断面, 其某一时段的所有车道断面的流量 $F = \{X_{a_1}, X_{a_2}, \dots, X_{a_m}\}$, 其中, $X_{a_1} = [x_{t-n}^{a_1}, x_{t-n-1}^{a_1}, \dots, x_t^{a_1}]$, $x_t^{a_1}$ 为 t 时刻 a_1 截面的车流量。将 F 通过

SVMD 分解, 得到分量序列矩阵 $X_A^u = \{X_{a_1}^u, X_{a_2}^u, \dots, X_{a_m}^u\}$, 其中

$$X_{a_1}^u = \begin{bmatrix} x_{t-n}^{a_1, u_1} & \dots & x_t^{a_1, u_1} \\ \vdots & \vdots & \vdots \\ x_{t-n}^{a_1, u_k} & \dots & x_t^{a_1, u_k} \end{bmatrix} \quad (9)$$

式中: 矩阵的行为车流量的分量序列, 矩阵的列为特定时间点的所有分量, k 为分量数。

步骤 2 通过相关性分析可得各车道截面的相关性系数矩阵 $p_{A \times m}$, 根据传感器位置可计算各车道截面的距离矩阵 $d_{A \times m}$ 。将经过 SVMD 处理的各车道截面流量值 X_A^u 作为 R-GCN 的节点输入, 将车道相关性系数及截面距离作为 R-GCN 的边输入, 由式(5)所示的 R-GCN 特性, 经多层 R-GCN 聚合更新可得新的车流量序列:

$$X_A^{u,r} = \{X_{a_1}^{u,r}, X_{a_2}^{u,r}, \dots, X_{a_m}^{u,r}\} \quad (10)$$

步骤 3 将异构图卷积的输出 $X_A^{u,r}$ 作为 Bi-GRU 层的输入, Bi-GRU 能同时捕捉序列数据的前、后向信息, 其包含复位门和更新门两个门结构, Bi-GRU 单元定义为

$$\begin{cases} r_t = \sigma(W_r X_t + U_r H_{t-1} + b_r) \\ u_t = \sigma(W_u X_t + U_u H_{t-1} + b_u) \\ \hat{H}_t = \text{Tanh}[W_h X_t + U_h (H_{t-1} r_t) + b_h] \\ H_t = u_t \hat{H}_t + (1 - u_t) H_{t-1} \end{cases} \quad (11)$$

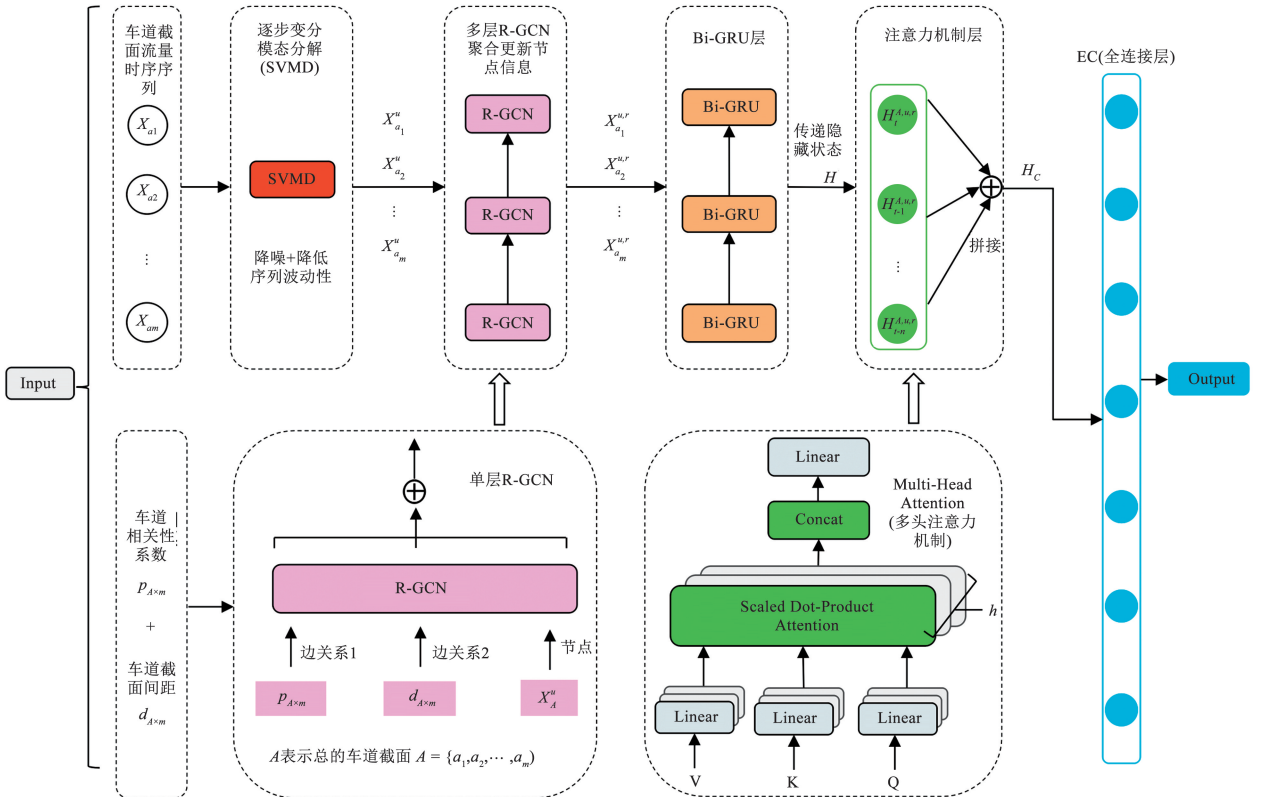


图 3 RSTGCN 整体模型架构

Fig. 3 Model architecture of RSTGCN

式中： θ 为 sigmoid 激活函数，更新隐藏状态为 Tanh 激活函数， r_t 和 u_t 分别为 t 时刻的复位门和更新门， H_{t-1} 和 H_t 分别为 t 时刻和前一时刻的隐藏状态， \hat{H}_t 为候选隐藏状态。

经过多层 Bi-GRU 后，将最后一层 Bi-GRU 的隐藏状态输出记为 H 。 H 包含了每个时间步下的隐藏状态，具体为

$$H = \text{Bi-GRU}(H_{t-n}^{A,u,r}, H_{t-n-1}^{A,u,r}, \dots, H_t^{A,u,r}) \quad (12)$$

步骤 4 将多头注意力机制的输入，隐藏状态 H ，转化为查询、键、值矩阵，由式(6)、(7)得出注意力分数值，再使用注意力分数值对值矩阵进行加权求和，得出每个注意力头输出，根据式(8)拼接多个注意力头输出，记为 H_c 。

步骤 5 将 H_c 输入全连接层进行映射，可得各车道截面的流量预测值 Y 。

2 实例验证

2.1 数据采集

数据来源于山西省的京昆高速(G5)、二广高速(G55)与太原绕城高速(G20003)互通式立体交叉路段，共包含 27 个断面分车道的地磁线圈传感器记录的交通流量信息。其采集时间间隔为 5 min，时间为 2018 年 4 月 1 日—4 月 30 日，如图 4 所示。图中标记点为传感器所在道路截面的点位。为保证数据可靠性，经数据检验后，共筛选出 113 个有效检测车道。



图 4 研究区域范围及线圈传感器点位信息

Fig. 4 Locations of the studied area and selected loop detector

2.2 车道流量聚类分析

将连续一周以 30 min 为时间间隔统计的车道流量序列作为依据对车道进行分类，为降低某一天数据的偶发性，取 2018 年 4 月 1 日—28 日连续 4 个周各车道各周天对应时段的均值，使用 Soft-DTW 度

量时间序列相似性，再通过 k -means 算法分类车道断面。采用肘部法则确定 k -means 算法的最佳聚类数，结果如图 5 所示。曲线拐点对应聚类数目为 4，因此宜将车道断面分为 4 类。




图 5 车道断面最优聚类数目

Fig. 5 Optimal number of clusters for lane classification

车道聚类结果如表 1 所示，4 类车道分别定义为密集型车道、稀疏型车道、早高峰型车道和晚高峰型车道。将各类车道对应时段的流量均值作为该类别的特征时序，如图 6 所示。4 种类别的车道时序特征具有明显差异，但工作日-休息日的特征均不相同。休息日早高峰推迟且强度较低，出行时间分布较为均衡，晚高峰也较为平缓。休息日的流量高峰常出现中午，体现了休闲活动出行时间的分布特性。

类别 1 车道全天均保持较高的车流量，且车流量均值最大，表明此类车道利用程度最高，可反映出行者的习惯和需求，定义其为密集型车道；类别 2 车道具有明显的早晚高峰和午间高峰，但车流量明显小于其他车道，其使用频率较低，定义其为稀疏型车道；类别 3 车道流量呈现出明显的早高峰，其他时段车流量较低，定义其为早高峰型车道；类别 4 车道与类别 3 相反，呈现出明显的晚高峰趋势，定义其为晚高峰型车道。

表 1 各类车道断面的特性

Tab. 1 Characteristics of various lane sections

类别	车道断面数量	所属类型
类别 1	46	密集型
类别 2	6	稀疏型
类别 3	28	早高峰型
类别 4	33	晚高峰型

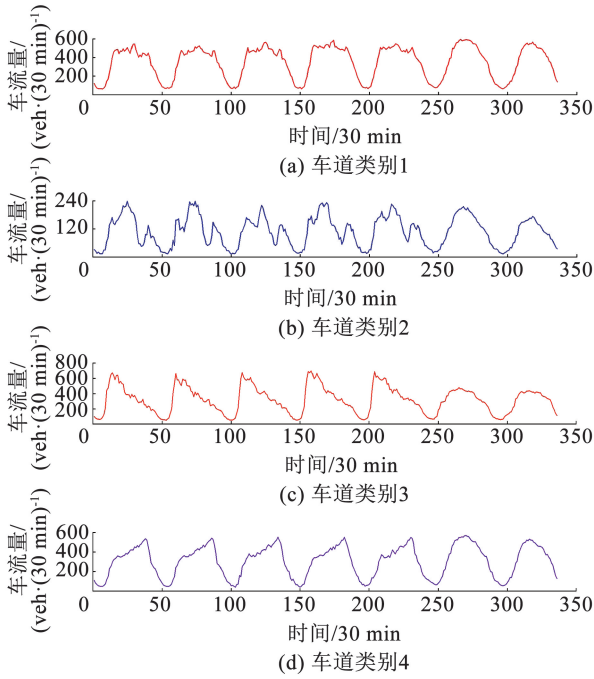


图 6 不同类别车道车流量时序特征

Fig. 6 Time series characteristics of traffic flow for each lane type

2.3 模态分解与车道自相关性分析

图 7 展示了某早高峰型车道一个月的车流量时序序列经 SVMD 分解后的分量图。SVMD 自适应最优参数组合 $[K, \alpha] = [7, 759]$, 其有 7 个 IMF 分量 (IMF1 ~ IMF7), 各分解分量代表车流量数据中具有周期性且无混叠部分的不同时间局部特征。

将 113 个车道断面的流量时序数据进行 Spearman 相关性分析, 其相关性系数矩阵如图 8 所示。由于上、下行车道相关性系数相对较小, 相邻车道相关性系数较大, 相关性系数矩阵区块化特征显著。

2.4 单步长预测精度分析

实验环境应用 TensorFlow 框架搭建, 优化器为 Adam, 堆叠 3 层 Bi-GRU, 初始化 R-GCN 双边关系权重比为 1:1, 后续模型会自动更新权重比例使得不同类型的边关系对节点表示的贡献最大化。实验设置不同隐藏层神经元数以及学习率以分析其对模型精度的影响, 最终隐藏层神经元数选值为 64, 学习率为 0.001, 此时模型具有较好的性能表现, 训练集与测试集的比例划分为 8:2, 历史输入步长为 10, 为了防止训练过拟合, 使用了早停法调整迭代次数, 最大迭代次数为 1 200, 同时选用 5 折交叉验证提高模型的泛化能力。

为验证所提模型有效性和预测的准确性, 选取 ARIMA、SVR、RF、LSTM、Bi-GRU 和 STGCN 作为对比模型, 为确保对比模型的公平性, 超参数调整使用了与所提模型相同的方法来确定。选取平均绝对误

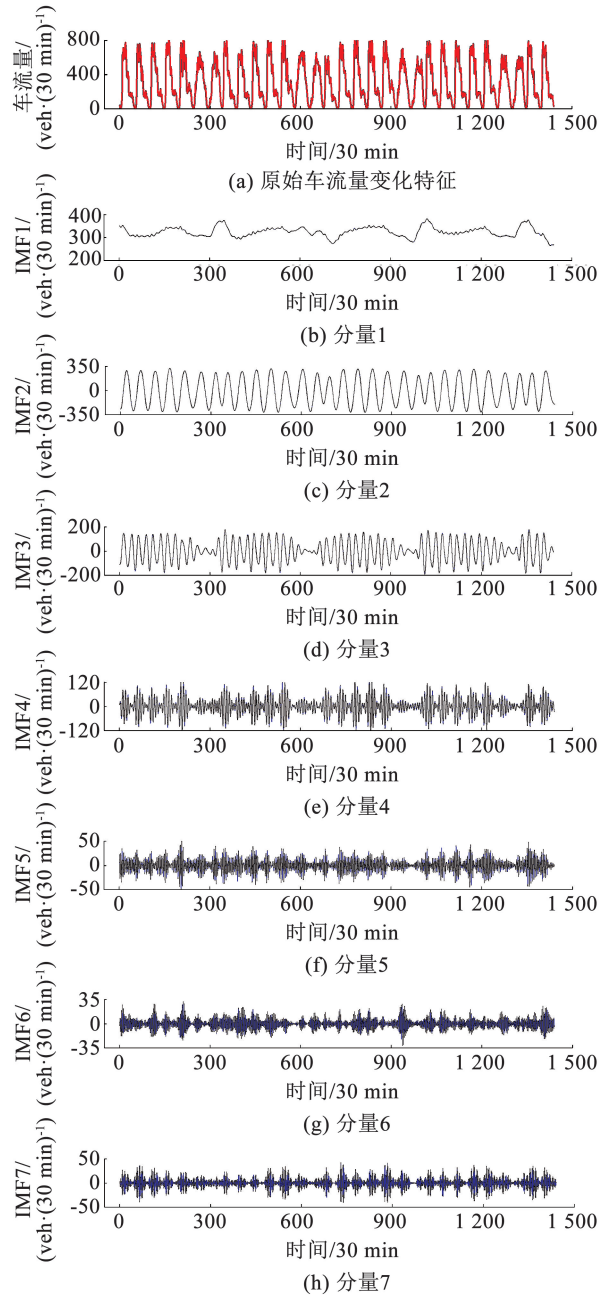


图 7 SVMD 分解后时序特征分量

Fig. 7 Decomposed time series components by SVMD

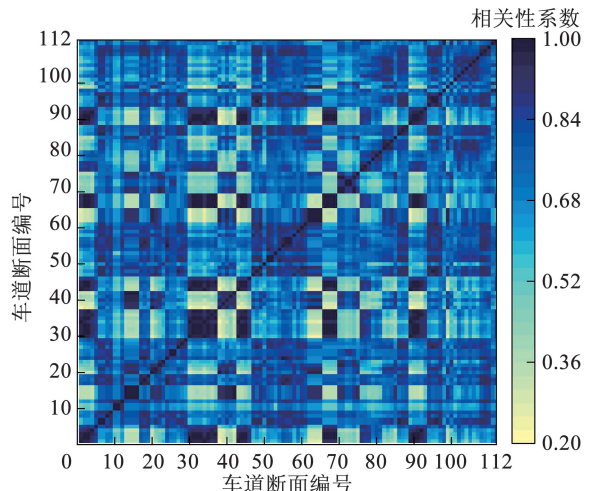


图 8 113 车道断面相关性系数

Fig. 8 Correlation coefficients of the selected 113 lane sections

差 MAE、均方根误差 RMSE 和决定系数 R^2 作为评价指标。

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \quad (13)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2} \quad (14)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - y'_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (15)$$

式中： y_i 和 y'_i 分别为真实值和预测值， \bar{y} 为真实值的平均值， n 为总样本数。

分别以 5、15、30 min 和 60 min 4 种时间粒度训练模型并进行单步预测。模型输入包含 113 个车道断面的车流量信息和空间信息。由表 2 可见，ARIMA 模型难以处理复杂的非线性关系，误差相对最高；SVR、RF 在处理长时间依赖关系上相对较弱，误差也较高；LSTM 能捕捉长期依赖信息，5 min 时间粒度下平均绝对误差比 SVR 降低了 5.34%；Bi-GRU 存在前、后向两个 GRU 层，能捕捉序列中过去和未来的信息，精度进一步提升；STGCN 适用于处理具有复杂空间和时间依赖关系的数据。STGCN 预测

在 5 min 时间粒度下比 SVR 模型的平均绝对误差和均方根误差分别降低 11.75% 和 14.37%；本文所构建模型综合效能最优；4 种时间粒度下，对比 7 种模型的预测效果，平均绝对误差分别降低了 11.21% ~ 24.05%、8.01% ~ 27.36%、8.91% ~ 27.74% 和 9.12% ~ 28.4%，均方根误差分别降低了 8.89% ~ 24.43%、7.14% ~ 24.79%、6.55% ~ 26.52% 和 8.73% ~ 28.24%， R^2 值为 0.962、0.969、0.956 和 0.955。

车道分类后，在 5 min 时间粒度下各类型车道预测结果如表 3 所示。其中，类别 2 和类别 4 车道因自身车道流量均值较小，MAE 和 RMSE 相比于整体预测的 5.236 和 7.986 明显减小，类别 1 和类别 3 车道流量远高于平均值，但分车道后，MAE 值和 RMSE 值提升不大；类别 2 车道由于序列波动性强， R^2 为 0.782 ~ 0.857；类别 1 车道和类别 4 车道序列平稳且规则性强， R^2 有所增加；所提模型分车道后整体预测的 MAE 和 RMSE 均值分别为 4.882 和 7.327，明显低于不分车道时的 5.236 和 7.986，整体预测精度提升，原因在于车道分类后，车道相关性系数增大。图 9 为 4 月 25 日—4 月 28 日 30 min 时间粒度下 4 种不同类型车道的预测效果。

表 2 4 种时间粒度下所有车道断面流量预测结果

Tab. 2 Traffic flow prediction results for all lane sections at four time granularities

模型	MAE				RMSE				R^2			
	5 min	15 min	30 min	60 min	5 min	15 min	30 min	60 min	5 min	15 min	30 min	60 min
ARIMA	6.894	16.759	31.976	47.896	10.568	26.356	51.245	73.114	0.921	0.92	0.912	0.918
SVR	6.682	15.865	29.623	45.652	10.236	25.683	48.682	69.365	0.924	0.925	0.917	0.920
RF	6.724	15.453	29.12	44.321	10.322	25.231	47.236	68.321	0.922	0.928	0.919	0.922
LSTM	6.325	14.345	27.589	41.35	9.765	24.356	45.356	63.255	0.937	0.938	0.927	0.934
Bi-GRU	6.224	14.128	27.256	40.289	9.542	23.453	44.368	62.147	0.939	0.94	0.93	0.937
STGCN	5.897	13.234	25.365	37.695	8.765	21.348	40.296	57.482	0.946	0.951	0.944	0.945
RSTGCN	5.236	12.174	23.105	34.259	7.986	19.823	37.657	52.466	0.962	0.969	0.956	0.955

表 3 5 min 时间粒度下各类别车道断面预测结果

Tab. 3 Prediction results for each category of lanes at the 5-minute time granularity

模型	MAE				RMSE				R^2			
	类别 1	类别 2	类别 3	类别 4	类别 1	类别 2	类别 3	类别 4	类别 1	类别 2	类别 3	类别 4
ARIMA	7.102	5.462	6.896	6.725	10.887	8.025	10.469	10.562	0.923	0.782	0.907	0.920
SVR	6.823	5.237	6.693	6.511	10.498	7.812	10.148	10.237	0.927	0.799	0.914	0.923
RF	6.852	5.335	6.748	6.548	10.574	7.868	10.267	10.315	0.925	0.792	0.912	0.921
LSTM	6.587	5.014	6.331	6.129	9.925	7.456	9.674	9.763	0.938	0.811	0.925	0.936
Bi-GRU	6.554	4.989	6.287	6.073	9.784	7.271	9.523	9.539	0.94	0.819	0.928	0.938
STGCN	6.179	4.526	5.993	5.741	9.015	6.856	8.696	8.76	0.946	0.832	0.937	0.945
RSTGCN	5.249	4.023	5.286	4.968	8.072	5.967	7.649	7.623	0.965	0.857	0.949	0.963

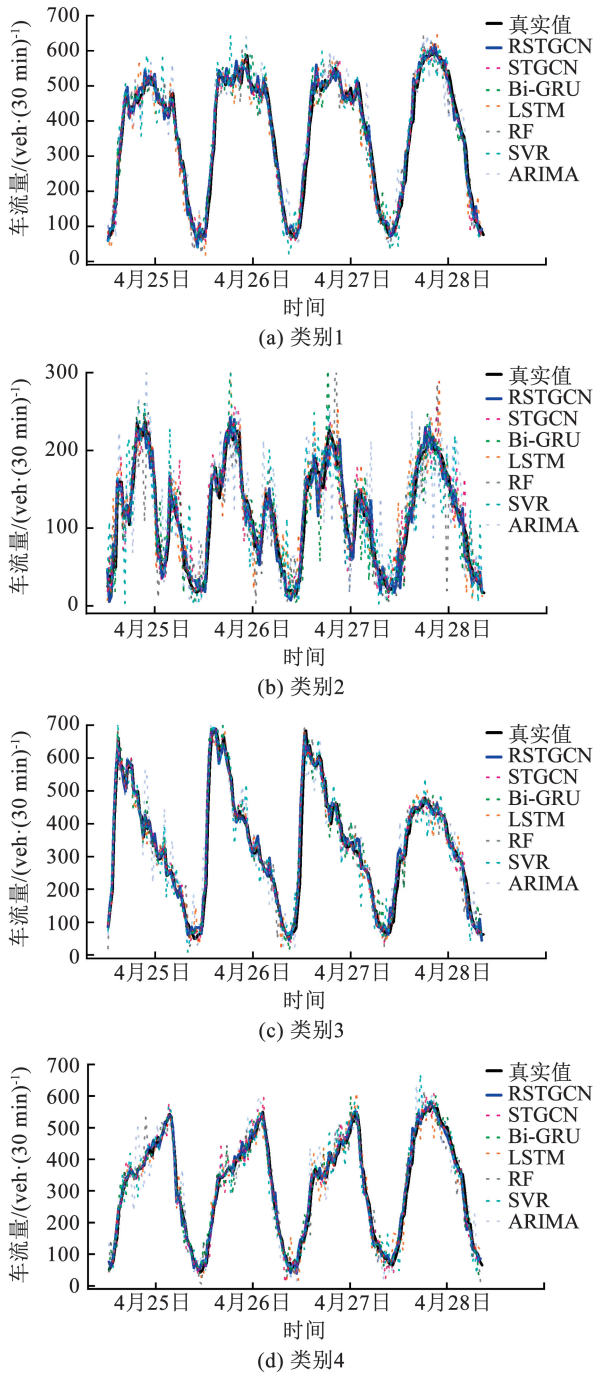


图 9 30 min 时间粒度下 4 种不同类型车道的流量预测结果
Fig. 9 Traffic flow prediction results for four lane types with the 30-minute time granularity

2.5 多步长预测精度分析

多步长的交通流量预测可以揭示交通流量的长期趋势,提供完整的预测路径,帮助分析高峰期和低谷期的规律,制定更有效的缓解措施;车道级多步长交通流量预测也可以满足更多实际交通运行场景需求,提前预测和调整车道流量,确保交通顺畅。

15 min 时间粒度下分别对所提模型和对比模型进行 12 个步长流量预测,结果如图 10 所示,随着预测步长的增加,模型的误差值均逐渐增大,原因在于时间维度上待预测的数据受历史邻近数据的影响程

度逐渐变小,以及空间维度上邻居节点的数据在持续变化。对比模型中 ARIMA 模型预测精度仍为最低,STGCN 效果相对较优,整体趋势与单步长预测类似;所提模型 MAE 值和 RMSE 值整体呈现线性变化且增幅不大,预测效果在多步长中仍为最佳,原因在于所提模型中含多头自注意力机制,便于提取长时间依赖特征,R-GCN 层捕捉了更多空间邻居节点信息,当预测步长为 12 时,所提模型 MAE 值和 RMSE 值较单步长预测仅增加了 15.82% 和 11.99%, R^2 可达 0.935。

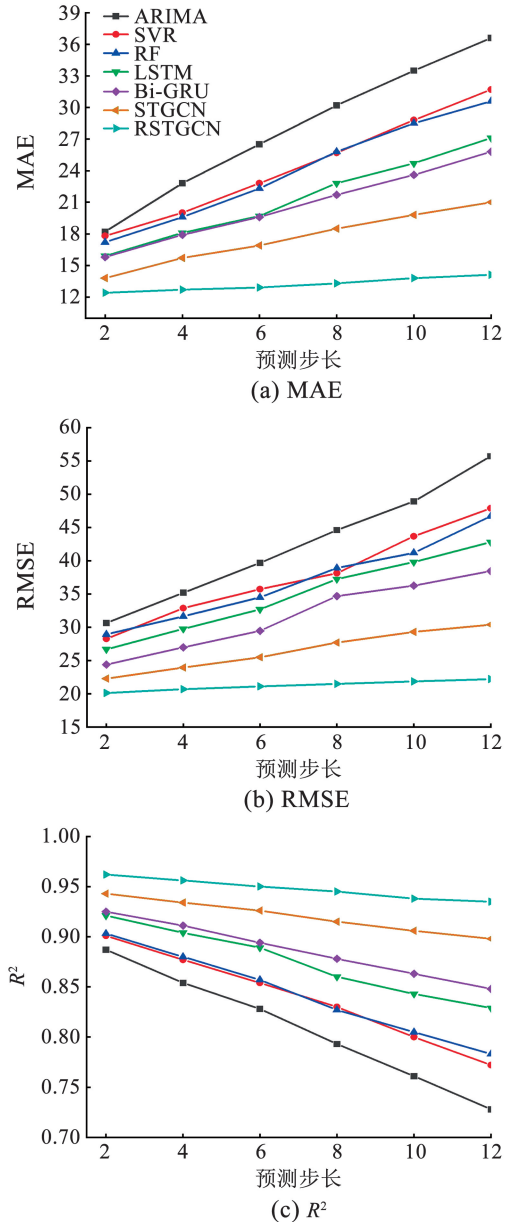


图 10 多步长交通流量预测效果

Fig. 10 Multistep traffic flow prediction performance

3 结 论

1) 考虑到车道级交通流量预测受多重时空特性影响,根据车道断面流量的不同对车道分类,建立

了一种基于模态分解和深度学习的车道级流量预测方法。通过山西省高速公路数据验证结果表明,所提方法可有效进行车道划分和精准预测车道级交通流量。

2) 实例验证结果表明,经软-动态时间规整和 k -means 聚类后,将车道分为 4 类。以 5、15、30 min 和 60 min 4 种时间粒度分别预测车道流量,所提方法效果均为最优,5 min 时间粒度下,所提方法预测的平均绝对误差和均方根误差较对比模型分别降低了 11.21% ~ 24.05% 和 8.89% ~ 24.43%。车道分类后,预测精度得到提升,整体平均绝对误差降为 4.882。15 min 时间粒度下多步长预测结果显示,所提方法误差变化最小,当步长为 12 时,平均绝对误差和均方根误差仅增加了 15.82% 和 11.99%。

3) 本文研究对象为高速公路车道,后续研究可拓展至城市道路,并可融合更多道路信息对车道分类,还可探究天气等外部因素对车道级流量预测精度的影响。

参考文献

- [1] 李巧茹, 刘佳欣, 陈亮, 等. 自适应 ABS 优化 RBF 神经网络的短时交通流预测[J]. 哈尔滨工业大学学报, 2023, 55(3): 93
LI Qiaoru, LIU Jiaxin, CHEN Liang, et al. Short-term traffic flow prediction based on adaptive BAS optimized RBF neural network[J]. Journal of Harbin Institute of Technology, 2023, 55(3): 93
- [2] 沈强儒, 杨少伟, 曹慧, 等. 立交区域交叉口交通信息识别概率预测[J]. 哈尔滨工业大学学报, 2020, 52(9): 152
SHEN Qiangru, YANG Saowei, CAO Hui, et al. Prediction for recognition probability of traffic information at intersection of interchanges[J]. Journal of Harbin Institute of Technology, 2020, 52(9): 152
- [3] JIANG Jiajia, LAI Songxuan, ZHU Yecheng, et al. DsDTW: local representation learning with deep soft-DTW for dynamic signature verification[J]. IEEE Transactions on Information Forensics and Security, 2022, 17: 2198
- [4] 杨彪, 闫国成, 刘占文, 等. 基于异构图学习的交通场景运动目标感知[J]. 交通运输工程学报, 2022, 22(3): 238
YANG Biao, YAN Guocheng, LIU Zhanwen, et al. Perception of moving objects in traffic scenes based on heterogeneous graph learning[J]. Journal of Traffic and Transportation Engineering, 2022, 22(3): 238
- [5] XIAN Yu, YIN Xinbao, QUAN Shi. STHSGCN: spatial-temporal heterogeneous and synchronous graph convolution network for traffic flow prediction[J]. Heliyon, 2024, 9(9): 19927
- [6] LI Zhenning, YU Hao, ZHANG Guohui, et al. Network-wide traffic signal control optimization using a multiagent deep reinforcement learning[J]. Transportation Research Part C: Emerging Technologies, 2021, 125: 103059
- [7] JAVANI B, BABAZADEH A, CEDRER A. Path-based capacity-restrained dynamic traffic assignment algorithm[J]. Transportmetrica B: Transport Dynamics, 2019, 7(1): 741
- [8] XIAO Jianli, LONG Baichao. A multi-channel spatial-temporal transformer model for traffic flow forecasting[J]. Information Science, 2024, 671: 120648
- [9] CAO Kerang, LIU Yaru, DUAN Lini, et al. Research on regional traffic flow prediction based on MGCN-WOALSTM[J]. IEEE Access, 2023, 11: 126436
- [10] XU Jinhua, LI Yuran, LU Wenbo, et al. A heterogeneous traffic spatio-temporal graph convolution model for traffic prediction[J]. Physica A: Statistical Mechanics and its Applications, 2024, 641: 129746
- [11] LI Yan, XU Jinhua, LI Yuran, et al. Estimation and prediction of freeway traffic congestion propagation using tagged vehicle positioning data[J]. Transportmetrica B: Transport Dynamics, 2024, 12(1): 2297143
- [12] ZHENG Liang, HUANG Huimin, ZHU Chuang, et al. A tensor-based k -nearest neighbors method for traffic speed prediction under data missing[J]. Transportmetrica B: Transport Dynamic, 2020, 8(1): 182
- [13] LI Fuxian, FENG Jie, YAN Huan, et al. Dynamic graph convolutional recurrent network for traffic prediction: benchmark and solution[J]. ACM Transactions on Knowledge Discovery from Data, 2023, 17(1): 1
- [14] GU Yuanli, LU Wenqi, QIN Lingqiao, et al. Short-term prediction of lane-level traffic speeds: a fusion deep learning model[J]. Transportation Research Part C: Emerging Technologies, 2019, 106: 1
- [15] 孟闯, 王慧. 多信息融合的时空图卷积交通流量预测模型[J]. 浙江大学学报(工学版), 2023, 57(8): 1541
MENG Chuang, WANG Hui. Traffic flow prediction model based on spatio-temporal graph convolution with multi-information fusion[J]. Journal of Zhejiang University (Engineering Science), 2023, 57(8): 1541
- [16] ZHAO Ling, SONG Yujiao, ZHANG Chao, et al. TGCN: a temporal graph convolutional network for traffic prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 21(9): 3848
- [17] BEIN D, VERMA A, EAPEN J. Improved big data stock index prediction using deep learning with CNN and GRU[J]. International Journal of Big Data Intelligence, 2020, 7(4): 202
- [18] XU Jinhua, LU Wenbo, LI Yuran, et al. A multi-directional recurrent graph convolutional network model for reconstructing traffic spatiotemporal diagram[J]. Transportation Letters, 2024, 16(5): 405
- [19] YANG Hanyi, DU Lili, ZHANG Guohui, et al. A traffic flow dependency and dynamics based deep learning aided approach for network-wide traffic speed propagation prediction[J]. Transportation Research Part B: Methodological, 2023, 167: 99
- [20] WANG Jiawei, CHEN Ruixiang, HE Zhaocheng. Traffic speed prediction for urban transportation network: a path based deep learning approach. [J]. Transportation Research Part C: Emerging Technologies, 2019, 100: 372
- [21] MA Yixuan, ZHANG Zhenji, IHLER A. Multi-lane short-term traffic forecasting with convolutional LSTM network[J]. IEEE Access, 2020, 8: 34629
- [22] KE R, LI Wan, CUI Zhiyong, et al. Two-stream multi-channel convolutional neural network for multi-lane traffic speed prediction considering traffic volume impact[J]. IEEE Access, 2020, 8: 42042
- [23] LU Wenqi, RUI Yikang, RAN Bin. Lane-level traffic speed forecasting: a novel mixed deep learning model[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(4): 3601
- [24] 赵阳阳, 夏亮, 江欣国. 基于经验模态分解与长短时记忆神经网络的短时地铁客流预测模型[J]. 交通运输工程学报, 2020, 20(4): 194
ZHAO Yangyang, XIA Liang, JIANG Xinguo. Short-term metro passenger flow prediction based on EMD-LSTM[J]. Journal of Traffic and Transportation Engineering, 2020, 20(4): 194
- [25] CHANG Zhihong, LIU Chunsheng, JIA Jianmin. STA-GCN: spatial-temporal self-attention graph convolutional networks for traffic-flow prediction[J]. Applied Sciences-basel, 2023, 13(11): 121