

基于数据编解码的时空交通流预测方法

龙佰超, 关为生, 肖建力

(上海理工大学 光电信息与计算机工程学院, 上海 200093)

摘要: 针对路网的拓扑信息不完整而无法实现时空结合交通流预测的情况, 提出了一种基于时间序列预测模型联合数据编解码机制的预测方法。对路网内路段交通流数据进行编码得到路网信息的链状结构, 以此获取路网结构中的拓扑信息; 通过时序模型对链状结构进行交通流预测, 完成对链状结构的时序特征提取; 最终, 通过解码方法得到路网的时空交通流预测结果。采用 GPS 数据, 选取不同路网进行对比实验, 引入数据编解码的时空交通流预测方法与时间序列模型进行比较, 并且与基线模型 HA 和 ARIMA 展开了对比实验。实验结果表明: 深度学习模型引入数据编解码机制后, 模型性能明显提升; 引入数据编解码机制的深度学习模型的性能比基线模型的性能更优越。该方法仅仅使用简单的时间序列深度网络再联合数据的编解码机制即可实现时空结合的交通流预测。

关键词: 智能交通系统; 交通流预测; 数据编解码; 时序模型; 深度学习

中图分类号: U 491.112

文献标志码: A

Spatio-temporal traffic flow prediction method based on data encoding and decoding

LONG Baichao, GUAN Weisheng, XIAO Jianli

(School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: A prediction method based on a time series prediction model combined with a data encoding and decoding mechanism was proposed for the situation that the topological information of the road network is incomplete, and it is not possible to realize the spatio-temporal traffic flow prediction. The chain structure of road network information was obtained by encoding the traffic flow data of road sections in the network, so as to obtain the topological information in the road network structure. The traffic flow prediction of the chain structure was carried out by the time series model. The extraction of the temporal features of the chain structure was completed. Finally, the spatio-temporal traffic flow prediction results of the road network were obtained by the decoding method. Different road networks and their GPS data were selected for comparison experiments. The spatio-temporal traffic flow prediction method of data encoding and decoding was introduced for comparison with the time series

收稿日期: 2022-12-30

基金项目: 国家自然科学基金资助项目(61603257, 61906121)

第一作者: 龙佰超(1997-), 男, 硕士研究生. 研究方向: 智能交通. E-mail: 212190376@st.usst.edu.cn

通信作者: 肖建力(1982-), 男, 副教授. 研究方向: 数据挖掘与大数据技术、机器学习与计算机视觉、智能交通与智慧城市. E-mail: audyxiao@sjtu.edu.cn

model and the baseline models of HA and ARIMA. The experimental results show that the performance of the deep learning model is significantly improved after the data encoding and decoding mechanism is introduced. The performance of the deep learning model with this mechanism is superior to that of the baseline model. The proposed method can achieve spatio-temporal traffic flow prediction only using a simple time series deep network combined with the data encoding and decoding mechanism.

Keywords: *intelligent transportation systems; traffic flow forecasting; data encoding and decoding; time series model; deep learning*

随着城市道路和车辆的增多,实时、准确的交通流预测尤为重要。单一的时间序列预测模型无法满足交通流预测的需求。路网中相邻道路之间相互影响,交通流预测任务必须同时考虑时间特性和空间特性。因此,基于时空特性的交通流预测方法成为当下智能交通领域的热门研究话题。

在特征提取的尺度上,模型可以分为3种:时序模型、空间模型和时空模型^[1]。时序模型和空间模型分别提取交通流数据的时间特征和空间特征。时空模型既能提取交通流数据的时间特征,也能提取空间特征,并且在交通流预测中取得了不错的效果。时序模型又可以分为传统模型和基于深度学习的模型。自回归综合移动平均模型^[2]、灰色预测模型^[3]、卡尔曼滤波模型^[4]、支持向量机回归模型^[5]、K最近邻模型^[6]、贝叶斯模型^[7]、模糊逻辑模型^[8]和人工神经网络模型^[9]为传统的时间序列模型。基于深度学习的时序模型有循环神经网络^[10]、长短期记忆^[11]和门控循环单元^[12]等。空间模型中的卷积神经网络适用于欧几里德空间,而图卷积网络可以从本质上描述空间特征,并提取复杂路网结构,但需要拥有路网中图结构的邻接矩阵等信息。路网交通情况十分复杂,这些方法的交通流预测性能需要进一步提升,因此,时空模型脱颖而出。当下时空模型大多数为时空混合模型,即为时间模型和空间模型的融合。在路网拓扑结构可以获得的情况下,混合模型可以得到不错的效果,但是,足够的拓扑数据不易获取。

综上,本文提出了一种基于数据编解码的时空交通流预测方法。在不能获取足够拓扑信息的情况下,此方法充分考虑交通流的时间特性和空间特性,利用数据编解码对路网进行空间特征的提取,运用时序模型对路网进行时间特征的提取,从而能更准确地预测实际交通状况,有效提高预测精度。

1 交通流预测方法概述

智能交通系统发展至今,许多学者提出了基于时间、空间和时空特性的交通流预测方法,不同的交通流预测方法在特征提取上各有不同。

1.1 基于时间特性的交通流预测方法

传统的基于时间特性的交通流预测方法少数为参数模型^[13],如自回归综合移动平均模型、灰色预测模型和卡尔曼滤波模型等,上述模型算法简单,计算方便。但是其依赖于系统模型的静态假设,不能反映交通数据的非线性和不确定性。而非参数模型^[14]在拥有充足历史数据的条件下,可以很好地解决这些问题。常见的非参数模型有支持向量机回归模型、K最近邻模型、贝叶斯模型、模糊逻辑模型和人工神经网络模型等。随着深度学习的发展,循环神经网络及其变种长短期记忆和门控循环单元成为当下常用的时间序列预测模型。

1.2 基于空间特性的交通流预测方法

卷积神经网络在处理规则的网格数据时效果十分显著,但是路网结构往往是不规则的图结构。相较于卷积神经网络,图卷积网络在处理非欧式结构数据上效果更好,可以用于捕获图数据的结构特征。由于两者所面对的数据结构不同,图卷积网络广泛应用于路网交通流预测,并且取得了良好的效果。在充足的路网拓扑数据下,图卷积网络在空间特征提取上有着不错的效果,如路网图结构的度矩阵、邻接矩阵等。

1.3 基于时空特性的交通流预测方法

许多学者将时间序列模型和空间序列模型组合成为时空混合模型,混合模型既能提取时间特征,还能提取路网的空间拓扑信息。Zhao等^[15]将图卷积网络与门控循环单元相结合,提出时间图卷积网络。Zhang等^[16]提出基于动态特征编码的时空模糊图卷积网络模型,该模型将图卷积网络

与长短期记忆网络相结合，同样达到了不错的时空预测效果。无论时序模型和空间模型如何组合，都需要充足的路网拓扑数据才可以进行交通流预测，而拓扑数据往往比较难以获取。Yu等^[17]通过图卷积和注意力机制捕获几何交通数据相关性，并使用生成式对抗学习框架内的编码器和解码器体系结构提取和扩展时间数据相关性。传统的统计学算法以及近年来的机器学习、深度学习算法都可以用于时间序列预测，不同的方法各有优劣。当同时预测多个时间序列，并且各个时间序列之间存在空间上的关系时，就不能只将每个时间序列单独建模，而需要考虑不同时间序列之间的空间依赖关系。基于时空特性的交通流预测方法主要为时序模型和空间模型组成的混合模型，在已知路网信息充足的情况下，上述方法有着不错的表现。但数据的获取往往十分困难，且路网信息不完整的情况长期存在。考虑道路拓扑数据获取困难等问题，本文提出基于数据编解码的时空交通流预测方法，该方法的具体流程如图1所示。

首先对初始路段数据进行初始化得到归一化的数据 X ；然后选取中心路段进行路网构建和数据

的编码，提取路网中隐藏的空间特征矩阵 $\hat{X}$ ，此过程将路网的拓扑结构信息编码为链状结构；将编码后的数据输入时序模型中提取路网的时间特征，得到编码数据矩阵 $\hat{Y}$ ；最后通过数据解码得到路网中道路的交通流数据 Y 。表1为本文符号说明。

表 1 符号说明
Tab.1 Symbol description

符号	符号意义
M	路网内路段总数
N	时间周期总数
R	路段编号集合
$x_{ij}(i=1,2,\cdots,N;j=1,2,\cdots,M)$	第 <i>i</i> 时刻 <i>j</i> 路段的数据
$x_n=[x_{n1}\ x_{n2}\ \cdots\ x_{nM}]^T(n=1,2,\cdots,N)$	<i>n</i> 时刻 <i>M</i> 路段数据列向量
$x'_m=[x_{1m}\ x_{2m}\ \cdots\ x_{Nm}](m=1,2,\cdots,M)$	<i>m</i> 路段 <i>N</i> 时刻数据行向量
$X=[x_1\ x_2\ \cdots\ x_N]=[x'_1\ x'_2\ \cdots\ x'_M]^T$	路网输入数据
$\hat{X}=[\hat{x}_1\ \hat{x}_2\ \cdots\ \hat{x}_N]=[\hat{x}'_1\ \hat{x}'_2\ \cdots\ \hat{x}'_M]^T$	编码后的路网输入数据
$\hat{Y}=[\hat{y}_1\ \hat{y}_2\ \cdots]=[\hat{y}'_1\ \hat{y}'_2\ \cdots]^T$	时序模型输出数据
$Y=[y_1\ y_2\ \cdots]=[y'_1\ y'_2\ \cdots]^T$	解码后的模型输出数据

2 路网输入数据的编码

道路交通流数据是常见的时间序列数据，用于描述交通现象随时间变化的情况。单个路段有多种表示形式，如经纬坐标、道路编号等。图2为路网结构的一个示例。

图2用数字编号代表路段名称。以路段5为路网的中心路段记录路网层次信息，具体的路网信息如表2所示。

其中，路段5为第0层，路段13，16，17，6，14为第1层，路段2，11，1，7，19，8，9，18，15，3为第2层。第1层的路段与第0层的中心路段相邻，第2层的路段通过第1层的路段与第0层相邻。由中心路段5出发构成的路网层次遍历如图3所示。

逐层之间父节点与子节点为相邻路段，并且具有空间依赖关系。具体的路网输入数据的编码算法如下：

- 步骤1 设置时间序列长度*N*的初始值，选取中心路段，获得路网遍历层数为*K*，令*i*=1；
- 步骤2 令*L*=0，*j*=1，获取第*L*层的路段数*W_L*；
- 步骤3 遍历第*L*层所有路段交通速度数据*x_{ij}*，




图 1 基于数据编解码时空交通流预测方法的流程图
Fig.1 Flow chart of the spatio-temporal traffic flow prediction method based on data encoding and decoding




图 2 路网结构示例

Fig.2 An example of the road network

每次遍历路段数据后 $j = j + 1$, 如果 $j > W_L$, 则执行步骤 4, 否则重复步骤 3;

步骤 4 $L = L + 1$, 如果 $L > K$, 则执行步骤 5, 否则重复步骤 3, 直到最后一个路段交通流速度数

表 2 路网信息

Tab.2 Road Network information

层数	路段编号
0	5
1	13, 16, 17, 6, 14
2	2, 11, 1, 7, 19, 8, 9, 18, 15, 3

据 x_{ij} 遍历结束, 此时遍历路段总数为 M ;

步骤 5 $\hat{x}_i = (\hat{x}_{i1} \hat{x}_{i2} \cdots \hat{x}_{iM})^T, i = i + 1$, 如果 $i > N$, 则执行步骤 6, 否则重复步骤 2~4, 直到遍历完所有时间序列;

步骤 6 将交通流速度数据 $\hat{x}_1, \hat{x}_2, \cdots, \hat{x}_N$ 拼接为矩阵 $\hat{X}$;

步骤 7 记录路网数据层次遍历的顺序信息, 得到路段编号集合 R 。例如根据图 3 所示的实例, 则 $R = \{\{5\}, \{13, 16, 17, 6, 14\}, \{2, 11, 1, 7, 19, 8, 9, 18, 15, 3\}\}$ 。




图 3 路网层次遍历

Fig.3 Hierarchical traversal of road network

由上述算法得到的路网输入数据编码形式如下:

$$\hat{X} = \begin{bmatrix} \hat{x}_{11} & \hat{x}_{12} & \cdots & \hat{x}_{1N} \\ \hat{x}_{21} & \hat{x}_{22} & \cdots & \hat{x}_{2N} \\ \vdots & \vdots & & \vdots \\ \hat{x}_{M1} & \hat{x}_{M2} & \cdots & \hat{x}_{MN} \end{bmatrix} \quad (1)$$

可以将其表示为行向量的形式, 即

$$\hat{X} = \begin{bmatrix} \hat{x}_1 & \hat{x}_2 & \cdots & \hat{x}_N \end{bmatrix} \quad (2)$$

路网输入数据编码可以总结为将路网复杂的拓扑结构映射为链状结构, 图 4 为路网输入数据编码的输入与输出。

其中, 原始道路数据为复杂的图结构, 红色路段为中心路段, 蓝色路段为相邻路段, 其次为次相邻路段。将其编码为链状数据结构输出, 路段的排序方式分别为中心路段、相邻路段和次相邻路段。时间维度上扫描的数据为 $1 \sim N$ 。




图 4 路网输入数据编码

Fig.4 Coding method of the network input data

3 时序模型

基于编解码的时空交通流预测方法在时序特征提取上采用循环神经网络 (recurrent neural network, RNN), 长短期记忆 (long short-term memory, LSTM)和门控循环单元 (gated recurrent unit, GRU)等模型, 这些模型都可以处理多元时间序列数据。RNN 结构简单, 但由于在进行反向传播的时候, 过长的序列导致梯度的计算异常, 发生梯度消失或爆炸, 所以, 传统循环神经网络在解决长序列之间的关联时, 效果很差。因此, 在 RNN 模型中加入内存单元或门控结构是解决以上问题的有效方法。LSTM 为 RNN 的变体, 在学习长期依赖性方面显示出很好的效果。相比于 LSTM 模型, GRU 模型结构更简单, 只有重置门

和更新门, 而且也能很好地解决时间序列的长期依赖性问题。

时间序列预测模型根据历史数据只可提取数据的时间特征, 最终得到预测结果。此时, 在交通流预测任务中, 预测结果未考虑路网内相邻道路之间的空间相关性, 道路之间的预测结果彼此相互独立。引入数据编解码后, 将通过数据编码得到的时间序列输入到时序模型中进行交通流预测, 得到对应步长的输出序列。**图 5** 为引入数据编解码后的时间序列预测图。

图 5 中: p 为历史窗口大小, 即历史数据的长度; q 为预测步长。 $q=1$ 为单步预测, 预测下一时刻的交通流速度; $q>1$ 为多步预测, 预测多个时间步的交通流速度。通过时间序列模型预测编码后交通流数据的结果。




图 5 时间序列预测
Fig.5 Time series forecasting

4 模型输出数据的解码

模型输出数据的解码将预测的链状结构时间片映射到路网复杂的拓扑结构中。本文根据保存的路段信息依次将预测后的交通流数据映射到路段编号中并输出, 即可得到整个路网的交通流预测, 模型输出数据解码示意图如**图 6** 所示。

图 6 中, 左边为时序模型的输出数据, 右边

为解码后的路网交通流预测结果。模型输出数据的解码算法如下:

- 步骤 1 设置预测步长 q 的初始值, 获取路段编号集合 R , 获得路网遍历层数为 K , 令 $i=1$; ;
- 步骤 2 令 $L=0, j=1$;
- 步骤 3 映射第 L 层所有路段交通流速度 y_{ij} ;
- 步骤 4 $L=L+1$, 如果 $L>K$, 执行步骤 5, 否则重复步骤 3, 直到最后一个路段交通流速度数据




图 6 模型输出数据的解码
Fig.6 Decoding method of the model output

映射结束;

步骤5 $y_i = (y_{i1} \ y_{i2} \ \cdots \ y_{iM})^T$, $i = i + 1$, 如果 $i > q$, 执行步骤6, 否则重复步骤2~4, 直到解码完所有的时间片;

步骤6 输出路网交通流预测结果 y_i , 其中 $i = 1, 2, \dots, q$ 。

5 实验

本文实验主要围绕两个核心问题进行展开: 深度学习模型引入编解码机制后, 性能指标是否得到提升; 引入编解码机制的深度学习模型的性能是否比基线模型的性能优越。为此, 实验的主要内容分为两个部分: 一是深度学习模型引入编解码机制前后性能的比较实验; 二是引入编解码机制的深度学习模型与基线模型性能的比较实验。

5.1 数据来源与预处理

本文所用的原始数据为上海市交通信息中心提供的GPS数据^[18]。实验时, 从原始数据中提取了所选路网的速度数据。数据的时间范围为2012年2月1日至2012年2月7日。数据的采样周期为2 min。

本文采用历史平均值法自动填充丢失的数据, 并且对数据进行归一化处理, 计算公式如下:

$$x'_{ij} = \frac{x_{ij} - \min x_{ij}}{\max x_{ij} - \min x_{ij}} \quad (3)$$

式中: x'_{ij} 为归一化后的第 i 时刻第 j 道路的交通流速度, $i = 1, 2, \dots, N$, $j = 1, 2, \dots, M$; x_{ij} 为第 i 时刻第 j 道路的交通流速度; $\min x_{ij}$ 为所有时刻所有道路交通流速度的最小值; $\max x_{ij}$ 为所有时刻所有道路交通流速度的最大值。

5.2 交通流预测方法的性能评价指标

本文使用的评价指标为平均绝对误差 (mean absolute error, MAE)、平均绝对百分比误差 (mean absolute percentage error, MAPE)、均方根误差 (root mean square error, RMSE)、对称平均绝对百分比误差 (symmetric mean absolute percentage error, SMAPE), 分别用 X_{MAE} , X_{MAPE} , X_{RMSE} , X_{SMAPE} 表示, 计算公式如下:

$$X_{MAE} = \frac{1}{NM} \sum_{i=1}^N \sum_{j=1}^M |y'_{ij} - y_{ij}| \quad (4)$$

$$X_{MAPE} = \frac{1}{NM} \sum_{i=1}^N \sum_{j=1}^M \left| \frac{y'_{ij} - y_{ij}}{y_{ij}} \right| \times 100\% \quad (5)$$

$$X_{RMSE} = \sqrt{\frac{1}{NM} \sum_{i=1}^N \sum_{j=1}^M (y'_{ij} - y_{ij})^2} \quad (6)$$

$$X_{SMAPE} = \frac{1}{NM} \sum_{i=1}^N \sum_{j=1}^M \frac{|y'_{ij} - y_{ij}|}{(|y'_{ij}| + |y_{ij}|)/2} \times 100\% \quad (7)$$

式中: NM 为测试集数据量; y_{ij} 为第 i 时刻第 j 道路交通流速度的真实值; y'_{ij} 为第 i 时刻第 j 道路交通流速度的预测值。

5.3 实验结果与分析

本文实验中历史窗口 $p = 12$, 时序模型采用 RMSprop 优化器, 自动保存最优模型。

5.3.1 深度学习模型引入数据编解码机制前后性能的比较

为说明深度学习模型引入编解码机制后模型的性能会提升, 在不同路网上分别对多种时序模型引入数据编解码机制。时序模型名称前的 ED 代表该模型引入了编解码的时空交通流预测方法。表3和表4分别为路网1和路网2中深度学习模型引入编解码机制后的实验结果对比。

结果表明, 引入数据编解码后, 时序模型 RNN, LSTM 和 GRU 中, 中心路段的交通流预测效果比引入前更好, 并且在路网1和2中 ED-RNN 的表现效果最佳; 路网1为上海市中心城区的路网结构, 与不引入数据编解码的时序模型相比, 路网1的 MAE 降低了 17.75%, MAPE 降低了 16.21%, RMSE 降低了 16.69%, SMAPE 降低了 19.63%。路网2为与路网1不同的中心城区的路网结构, 路网2的 MAE 减少了 14.42%, MAPE 减少了 10.87%, RMSE 减少了 10.12%, SMAPE 减少了 14.54%。在多个时间序列预测模型中引入数据编解码机制, 结果显示, 引入数据编解码后模型的性能均会有所提升。

5.3.2 引入编解码机制的深度学习模型与基线模型的性能比较

为说明引入编解码机制的深度学习模型比基线模型的交通流预测结果更能体现真实的交通状况, 分别在路网1和路网2中比较 ED-RNN 与基线模型的交通流预测。目前, 主流的交通流预测方法多为时空结合的交通流预测方法, 这些方法需要拥有充足的路网拓扑信息。虽然模型可达到不错的预测效果, 但模型复杂不易实现, 且算法的时间复杂度和空间复杂度都很高。而本文方法具有模型简单、算法易于实现等优点, 所以本文

的基线模型选取传统的交通流预测模型 HA 与 ARIMA。选取2012年2月1日18:30到2012年2月1日19:28路网1和路网2的中心路段进行模型交通流预测结果对比，如图7和图8所示。结果显示

表 3 路网 1 中深度学习模型引入编解码机制的实验对比

Tab.3 Experimental results comparison of deep learning models introducing codec mechanisms in road network 1

模型	评价指标				平均性能提升/%
	X_{MAE}	$X_{MAPE}/\%$	X_{RMSE}	$X_{SMAPE}/\%$	
RNN	3.2717	20.5364	5.2085	18.1020	17.9673
ED-RNN	2.7500	17.1000	4.2900	14.2000	
LSTM	3.6465	20.8791	5.2419	18.4732	18.7436
ED-LSTM	2.9100	17.1000	4.3900	14.7000	
GRU	3.5589	20.5306	5.1721	18.0486	15.2439
ED-GRU	2.9500	17.7000	4.4900	15.0000	

表 4 路网 2 中深度学习模型引入编解码机制的实验对比

Tab.4 Experimental results comparison of deep learning models introducing codec mechanisms in road network 2

模型	评价指标				平均性能提升/%
	X_{MAE}	$X_{MAPE}/\%$	X_{RMSE}	$X_{SMAPE}/\%$	
RNN	2.9061	11.2230	3.5250	11.5482	14.6809
ED-RNN	2.4100	9.7700	3.1200	9.5600	
LSTM	2.7132	10.7048	3.4081	10.8451	5.7989
ED-LSTM	2.5400	10.2000	3.2300	10.1000	
GRU	3.0015	11.5013	3.6294	11.9281	16.4993
ED-GRU	2.4277	9.8250	3.1435	9.6716	




图 7 路网 1 中心路段预测结果

Fig. 7 Road network 1 center section forecast results




图 8 路网 2 中心路段预测结果

Fig. 8 Road network 2 center section forecast results

示，相较于基线模型，RNN 在引入数据编解码后的交通流预测结果更趋近真实速度曲线。

通过 MAE，MAPE，RMSE 和 SMAPE 4 种评价指标对模型性能进行比较，以及根据预测结果分析表明，路网拓扑信息不充足的情况下，在深度学习模型上引入编解码机制可以有效地提高交通流预测的准确性。

6 结束语

基于数据编解码的时空交通流预测方法对路网数据进行编码提取空间特征，再利用时序模型提取路网时间特征，最终解码得到路网的交通流预测。通过将数据进行编解码与时序模型的结合，可以同时提取时空特征，获得更高的准确度。将数据编解码的时空交通流预测方法在不同路网上进行测试，并与传统方法进行对比，实验结果表明，在无法提取充足的路网信息时，通过在时序模型上引入数据编解码方法可得到不错的预测效果。相比于目前已有的交通流预测方法，本文方法所训练的模型更简单和高效。在未来的研究工作中，为了使模型预测准确度提高，还需要考虑多重外部因素影响，比如节假日、温湿度以及降雨、雪量等。

参考文献:

[1] WU Z H, PAN S R, CHEN F W, et al. A comprehensive survey on graph neural networks[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 32(1): 4–24.

[2] WILLIAMS B M, HOEL L A. Modeling and forecasting

- vehicular traffic flow as a seasonal ARIMA process: theoretical basis and empirical results[J]. [Journal of Transportation Engineering](#), 2003, 129(6): 664–672.
- [3] DUAN H M, XIAO X P. A multimode dynamic short-term traffic flow grey prediction model of high-dimension tensors[J]. *Complexity*, 2019, 2019: 9162163.
- [4] CAI L R, ZHANG Z C, YANG J J, et al. A noise-immune Kalman filter for short-term traffic flow forecasting[J]. [Physica A:Statistical Mechanics and its Applications](#), 2019, 536: 122601.
- [5] WU C H, HO J M, LEE D T. Travel-time prediction with support vector regression[J]. [IEEE Transactions on Intelligent Transportation Systems](#), 2004, 5(4): 276–281.
- [6] 张晓利, 贺国光, 陆化普. 基于 K-邻域非参数回归短时交通流预测方法 [J]. *系统工程学报*, 2009, 24(2): 178–183.
- [7] WESTGATE B S, WOODARD D B, MATTESON D S, et al. Travel time estimation for ambulances using Bayesian data augmentation[J]. *The Annals of Applied Statistics*, 2013, 7(2): 1139–1161.
- [8] YIN H B, WONG S C, XU J M, et al. Urban traffic flow prediction using a fuzzy-neural approach[J]. [Transportation Research Part C:Emerging Technologies](#), 2002, 10(2): 85–98.
- [9] HUANG W H, SONG G J, HONG H K, et al. Deep architecture for traffic flow prediction: deep belief networks with multitask learning[J]. [IEEE Transactions on Intelligent Transportation Systems](#), 2014, 15(5): 2191–2201.
- [10] FU R, ZHANG Z, LI L. Using LSTM and GRU neural network methods for traffic flow prediction[C]// *Proceedings of the 2016 31st Youth Academic Annual Conference of Chinese Association of Automation*. Wuhan: IEEE, 2016: 324–328.
- [11] 刘昶. 基于时间序列的经典模型和 LSTM 模型的城市宏观行程速度预测研究 [D]. 北京: 北京交通大学, 2019.
- [12] 赵建东, 申瑾, 刘麟玮. 多源数据驱动 CNN-GRU 模型的公交客流量分类预测 [J]. [交通运输工程学报](#), 2021, 21(5): 265–273.
- [13] VLAHOGIANNI E I, GOLIAS J C, KARLAFTIS M G. Short-term traffic forecasting: overview of objectives and methods[J]. [Transport Reviews](#), 2004, 24(5): 533–557.
- [14] VAN LINT H, VAN HINSBERGEN C. Short-term traffic and travel time prediction models[M]//*Transportation Research Board of the National Academies. Transportation Research Circular E-C168: Artificial Intelligence Applications to Critical Transportation Issues*. Washington: Transportation Research Board of the National Academies, 2012, 22: 22–41.
- [15] ZHAO L, SONG Y J, ZHANG C, et al. T-GCN: a temporal graph convolutional network for traffic prediction[J]. [IEEE Transactions on Intelligent Transportation Systems](#), 2020, 21(9): 3848–3858.
- [16] ZHANG S, CHEN Y, ZHANG W Y. Spatiotemporal fuzzy-graph convolutional network model with dynamic feature encoding for traffic forecasting[J]. [Knowledge-Based Systems](#), 2021, 231: 107403.
- [17] YU J J Q. Citywide traffic speed prediction: a geometric deep learning approach[J]. [Knowledge-Based Systems](#), 2021, 212: 106592.
- [18] XIAO J L, WANG Z H. Traffic speed cloud maps: a new method for analyzing macroscopic traffic flow[J]. [Physica A:Statistical Mechanics and its Applications](#), 2018, 508: 367–375.

(编辑: 丁红艺)