

文章编号:1007-5321(2020)05-0009-06

DOI:10.13190/j.jbupt.2019-243

# 基于 CNN-ResNet-LSTM 模型的城市短时 交通流量预测算法

蒲悦逸<sup>1</sup>, 王文涵<sup>1</sup>, 朱强<sup>1</sup>, 陈朋朋<sup>1,2</sup>

(1. 中国矿业大学 计算机科学与技术学院, 徐州 221116;

2. 中国矿业大学 矿山数字化教育部工程研究中心, 徐州 221116)

**摘要:** 针对交通流量特性和外部因素对交通流量预测结果的影响,提出了一种对城市短时交通流量预测的模型 CNN-ResNet-LSTM,将卷积神经网络(CNN)、残差神经网络(ResNet)和长短期记忆循环神经网络(LSTM)集成到一个端到端的网络框架。利用卷积神经网络来捕获城市区域间交通流量的局部空间特征,并在卷积神经网络中加入多个残差神经网络来加深网络深度,可提高预测的准确性;利用长短期记忆循环神经网络来捕获交通流量数据的时间特征;利用相应的权重将2个网络的输出结果融合,得到通过轨迹数据预测的结果;最后与外部因素融合,得到城市区域的交通流量预测值。用北京市轨迹交通数据对该模型进行验证,CNN-ResNet-LSTM模型不仅在准确率方面比传统模型高,而且在保证预测准确率的情况下,模型使用的参数也少。

**关键词:** 短时交通流量预测;深度学习;长短期记忆循环神经网络;卷积神经网络

中图分类号: TP18

文献标志码: A

## Urban Short-Term Traffic Flow Prediction Algorithm Based on CNN-ResNet-LSTM Model

PU Yue-yi<sup>1</sup>, WANG Wen-han<sup>1</sup>, ZHU Qiang<sup>1</sup>, CHEN Peng-peng<sup>1,2</sup>

(1. School of Computer Science and Technology, China University of Mining and Technology, Xuzhou 221116, China;

2. Mine Digitization Engineering Research Center of the Ministry of Education, China University of Mining and Technology, Xuzhou 221116, China)

**Abstract:** With the continuous advancement of smart city construction, urban short-term traffic flow forecasting becomes more and more important. According to the influence of traffic flow characteristics and external factors on traffic flow forecast results, the model CNN-ResNet-LSTM for urban short-term traffic flow forecasting is proposed. The model integrates convolutional neural networks(CNN), residual neural units(ResNet) and long-short-term memory networks(LSTM) into an end-to-end network framework. The convolutional neural network is used to capture the local spatial characteristics of traffic flow, and multiple residual neural units are added to deepen the network depth and improve the prediction accuracy. On the other hand, the long short-term memory-cycle neural network is used to capture temporal characteristics of traffic flow data. The output results of the two networks are combined by the corresponding weights to obtain the predicted results through the trajectory data. Finally, the traffic flow prediction values of the urban areas are obtained by fusing with external factors. Through the verification of the

收稿日期: 2019-11-26

基金项目: 徐州市科技计划项目(KC18061); 国家自然科学基金项目(51674255)

作者简介: 蒲悦逸(1994—), 男, 硕士生。

通信作者: 陈朋朋(1983—), 男, 教授, E-mail: chenp@cumt.edu.cn.

CNN-ResNet-LSTM model by Beijing data, the model is not only higher in accuracy than the traditional model, but also has fewer parameters in the case of ensuring the accuracy of prediction.

**Key words:** traffic flow forecasting; deep learning; long short-term memory network; convolutional neural network

智能交通系统(ITS, intelligent traffic system)的完善是建设智能城市的主要环节<sup>[1]</sup>,智能交通系统能缓解交通拥堵,减少车辆尾气排放,提高交通运营效率<sup>[2]</sup>. 通过将卷积神经网络(CNN, convolutional neural networks)、残差神经网络(ResNet, residual neural units)和长短期记忆循环神经网络(LSTM, long-short-term memory networks)集成到一个端到端的深度学习网络 CNN-ResNet-LSTM,能同时考虑轨迹数据和外部因素对交通流量的影响,从而进行短时预测. 经实验结果验证,模型在保证预测准确率的情况下,减少了模型的参数.

传统的流量预测方法很难对大规模的数据进行准确预测<sup>[3-4]</sup>. 深度学习已在许多领域被证明取得了成功,例如图像、音频和语言学习任务<sup>[5]</sup>,单一神经网络模型无法充分提取交通流量数据时空特征<sup>[6-8]</sup>. 为了充分发挥各模型的优势, Bates 和 Granger<sup>[9]</sup>提出了组合预测的思想. 众多研究人员开始用组合模型对交通流量进行预测<sup>[10-12]</sup>.

## 1 短时交通流量预测问题

短时交通流量预测问题定义为:在一个确定的时间间隙内预测某一观测点在下一个时间间隙的交通流量,时间间隙通常选择 5~30 min,第  $i$  个观测点在第  $t$  个时间间隙的流量记作  $f_{i,t}$ ,在间隙  $T$  时,交通流量序列  $F = \{f_{i,t} | i \in D, t = 1, 2, \dots, T\}$  ( $D$  是预测区域中全部的观测点),此时流量预测任务为预测间隙  $T+1$  的交通流量  $f_{i,T+1}$  或者  $T+n$  的交通流量  $f_{i,T+n}$ . 然而,精确的预测受 3 个因素影响,设某一时间间隙的交通流量为  $X$ .

### 1) 临近性

$X_c = (X_{t_0-T_h+3}, X_{t_0-T_h+2}, X_{t_0-T_h+1}, \dots, X_{t_0}) \in R^{2 \times M \times K}$  其中  $R$  为轨迹集合,即每一个时间间隙的交通流量往往受前一个时间间隙流量的影响,同时也会影响下一个时间间隙的流量. 随着人群上下班,一天中城市交通流量最为活跃的时间段分别为早、晚高峰. 图 1 所示为北京市一天中进入某一区域的交通流量,可以看出,9:00、12:00、17:30 的交通流量较多.

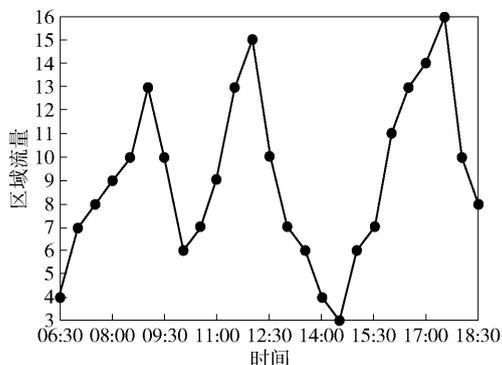


图1 北京市一天的交通流量

### 2) 趋势性

$$X_1 = (X_{t_0-T_m+3}, X_{t_0-T_m+2}, X_{t_0-T_m+1}, \dots, X_{t_0}) \in R^{2 \times M \times K}$$

图 2 所示为北京市某一区域 2015-03-12—2015-06-12 连续 4 个月在 12 号 11:30—12:00 的出租车流量,能够看出,人们喜欢在天气凉爽的月份出行,随着温度升高,人们越来越喜欢待在家里.

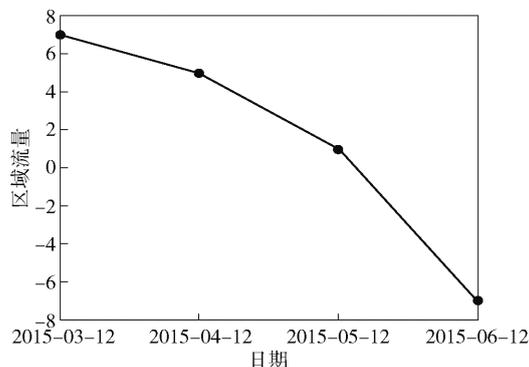


图2 北京市交通流量趋势性

### 3) 周期性

$$X_p = (X_{t_0-T_d+3}, X_{t_0-T_d+2}, X_{t_0-T_d+1}, \dots, X_{t_0}) \in R^{2 \times M \times K}$$

由预测时间间隙之前多天与预测时间间隙相同的序列组成. 城市区域的交通流量具有周期性,即同一月份中每一天相同时间间隙的车流大致相同,图 3 为 2013-07-01—2013-07-07 期间北京市从周一到周日 12:30—13:00 时的出租车入流的趋势图. 可以看到,在工作日时进入该区域的出租车数量相近,而节假日进入该区域的出租车数量明显多于工作日.

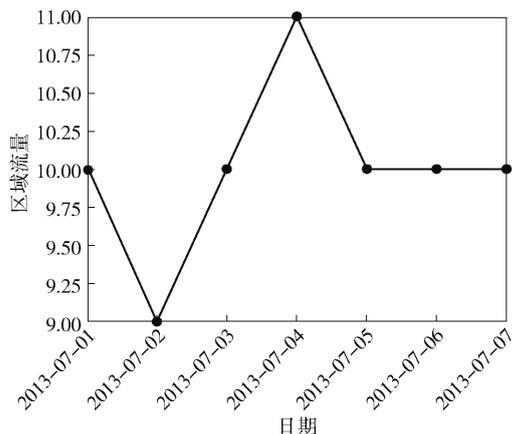


图 3 北京市交通流量周期性

为了更好地考虑空间和时间上各因素对交通流量的影响,将城市区域根据经纬度划分成一个  $M \times N$  的网格地图,其中 1 个网格表示 1 个区域. 第  $m$  行第  $k$  列网格  $(m, k)$  的入流和出流定义为

$$x_t^{\text{in},m,k} = \sum_{T_r \in R} |\{n > 1 | h_{n-1} \notin (m, k) \wedge h_n \in (m, k)\}| \quad (1)$$

$$x_t^{\text{out},m,k} = \sum_{T_r \in R} |\{n \geq 1 | h_n \in (m, k) \wedge h_{n+1} \notin (m, k)\}| \quad (2)$$

其中:  $T_r: h_1 \rightarrow h_2 \rightarrow \dots \rightarrow h_{T_r}$  为  $R$  中的一个轨迹,  $h_n$  为地理位置的坐标,  $h_i \in (m, k)$  为点  $h_n$  在网格  $(m, k)$

中. 对每个时间间隔  $t$ , 将  $M \times N$  个区域的入流  $(X_t)_{0,m,k} = x_t^{\text{in},m,k}$  和出流  $(X_t)_{1,m,k} = x_t^{\text{out},m,k}$  为  $X_t$ ,  $X_t \in R^{2 \times M \times K}$ .

采取的时间间隔为 30 min, 即每 30 min 统计一次城市区域内所有网格的入流与出流情况, 并建立时空矩阵  $P_t$  为

$$P_t = \begin{bmatrix} X_{\text{lon}_1, \text{lat}_1} & \dots & X_{\text{lon}_1, \text{lat}_k} \\ \vdots & & \vdots \\ X_{\text{lon}_m, \text{lat}_1} & \dots & X_{\text{lon}_m, \text{lat}_k} \end{bmatrix} \quad (3)$$

## 2 网络模型

通过将卷积神经网络、残差神经单元和长短期记忆循环神经网络集成到一个端到端的深度学习网络, 网络结构如图 4 所示. 一方面使用卷积神经网络来捕获城市区域内交通数据的局部空间特征, 并使用残差神经单元来加深网络的深度从而提高预测的准确性; 另一方面, 使用长短期记忆循环神经网络来捕获交通流量间数据的时间特征, 然后将 2 个网络的输出利用相应的权重矩阵融合, 最后与外部因素(天气、温度、风速等)融合, 从而实现预测每个区域短时的交通流量.

### 2.1 卷积神经网络

首先构建  $X_c$ ,  $X_t$  和  $X_p$  三个模块. 这 3 个模块通过一个相同的二维卷积神经网络结构以模拟时间临

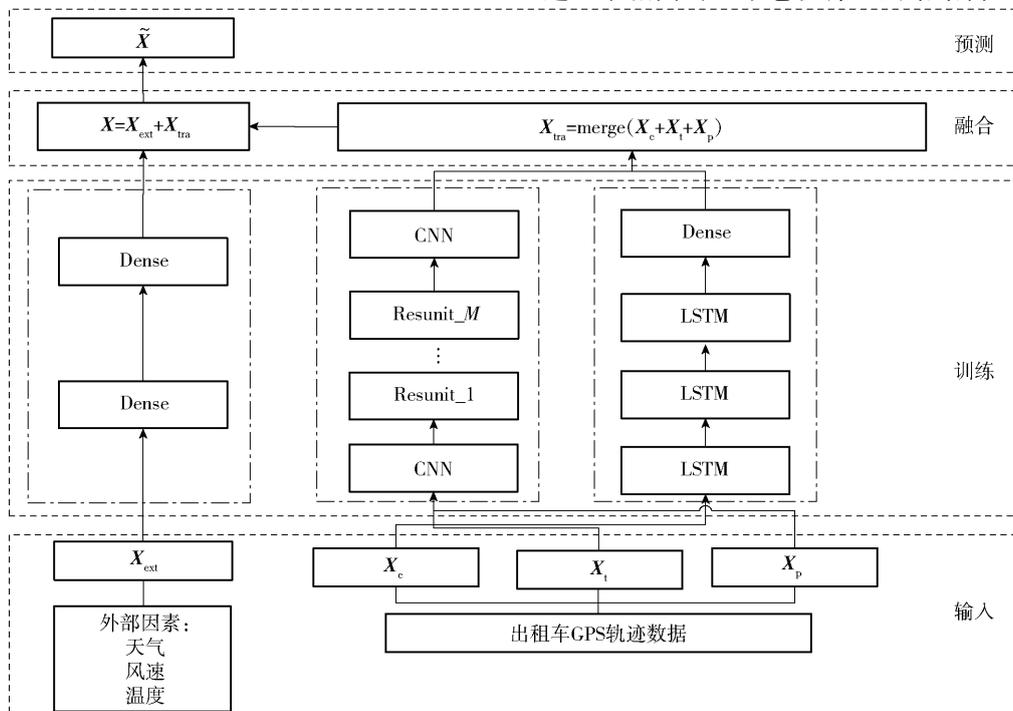


图 4 CNN-ResNet-LSTM 网络结构

近性、趋势性以及周期性。

卷积算子定义为

$$f(\mathbf{W} * \mathbf{X} + b) \quad (4)$$

其中:  $f$  为激活函数,  $*$  为卷积运算,  $\mathbf{W}$  为权重矩阵,  $b$  为偏置值。

临近性、趋势性、周期性 3 个模块的卷积算子分别为

$$\mathbf{X}_c^{(l)} = f \left( \sum_{j=1}^{l_c} \mathbf{W}_{c,j}^{(l)} * \mathbf{X}_{t-j} + b_c^{(l)} \right) \quad (5)$$

$$\mathbf{X}_t^{(l)} = f \left( \sum_{j=1}^{l_t} \mathbf{W}_{t,j}^{(l)} * \mathbf{X}_{t-j} + b_t^{(l)} \right) \quad (6)$$

$$\mathbf{X}_p^{(l)} = f \left( \sum_{j=1}^{l_p} \mathbf{W}_{p,j}^{(l)} * \mathbf{X}_{t-j} + b_p^{(l)} \right) \quad (7)$$

## 2.2 残差神经元

通过加入多个残差单元以解决模型过拟合问题,如式(8)所示,在卷积层的基础上增加了  $M$  个残差单元。

$$\mathbf{X}_c^{(l+1)} = \mathbf{X}_c^{(l)} + \vartheta(\mathbf{X}_c^{(l)}; \theta_c^{(l)}), \quad l = 1, 2, \dots, M \quad (8)$$

其中:  $\vartheta$  为残差函数,  $\theta_c^{(l)}$  为在  $l$  层的残差单元所有能够学习的参数。

## 2.3 长短期记忆循环神经网络

LSTM 的输入通常是序列数据,因此需要对初始输入数据进行处理,首先将卷积神经网络的每个输入,即图中的  $\mathbf{X}_c, \mathbf{X}_t, \mathbf{X}_p$  展开成一维矩阵,然后将其转换成适合 LSTM 网络的输入形式。通过不同门的功能,使得 LSTM 网络能够处理具有长期依赖性的交通流量数据。

## 2.4 融合

在进行多源数据融合时,首先将  $\mathbf{X}_c, \mathbf{X}_t, \mathbf{X}_p$  利用权重矩阵进行融合得到轨迹数据  $\mathbf{X}_{tra}$ 。

$$\mathbf{X}_{tra} = \mathbf{W}_c \circ \mathbf{X}_c + \mathbf{W}_t \circ \mathbf{X}_t + \mathbf{W}_p \circ \mathbf{X}_p \quad (9)$$

其中  $\circ$  为哈达马积。

其次将外部数据  $\mathbf{X}_{ext}$  与轨迹数据  $\mathbf{X}_{tra}$  利用  $\tanh$  函数融合得到最终时间间隔  $t$  的交通流量预测值为

$$\tilde{\mathbf{X}} = \tanh(\mathbf{X}_{ext} + \mathbf{X}_{tra}) \quad (10)$$

其中:  $\tanh$  为双曲正切函数,确保最终结果在  $[-1, 1]$ 。

# 3 实验

## 3.1 数据集描述

利用北京市数据<sup>[13]</sup>对 CNN-ResNet-LSTM 模型

进行验证,北京市数据由出租车自带 GPS 设备收集的出租车轨迹数据和北京市的外部因素数据组成,信息如表 1 所示。

表 1 数据集信息

参数	数值
数据类型	出租车 GPS 数据
	2013-07-01—2013-10-30
	2014-03-01—2014-09-30
时间跨度	2015-03-01—2015-09-30
	2015-11-01—2016-04-10
时间间隔/min	30
外部因素	
天气情况	16 种天气类型(晴天,下雪等)
温度/°C	[-24.6, 41.0]
风速/(mile·h <sup>-1</sup> )	[0, 48.6]

## 3.2 评价标准

利用均方根误差(RMSE, root mean square error)和平均绝对百分比误差(MAPE, mean absolute percentage error)对模型进行评价, RMSE 和 MAPE 是常见量化模型优劣的重要标准,其值分别为

$$r_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (11)$$

$$m_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (12)$$

## 3.3 超参数影响

模型自身参数的改变同样会影响最终的预测结果。因此,为得到最好的预测结果,对模型使用的参数进行了自身的对比实验。首先,对卷积核尺寸大小从  $2 \times 2$  增加到  $7 \times 7$  时分别进行了实验,实验结果如图 5(a) 所示。当卷积核尺寸大小从  $2 \times 2$  到  $3 \times 3$  时, RMSE 下降明显;当卷积核尺寸大小从  $3 \times 3$  变化到  $6 \times 6$  时, RMSE 变化不很明显;而卷积核尺寸大小为  $7 \times 7$  时, RMSE 变大。由于模型训练时长通常随着卷积核额的增大而加长,所以将卷积核尺寸大小设置为  $3 \times 3$ ;其次,对残差神经单元的个数从 7 ~ 13 分别进行了实验,实验结果如图 5(b) 所示。随着残差神经单元从 7 增加到 11,模型深度加深, RMSE 一直减小。但是,当深度继续加深,即残差神经单元从 11 增加到 13 时, RMSE 反而增大。因此选择的残差单元数为 11。最后,对实验迭代次数进行比较, RMSE 和 MAPE 的值分别如图 5(c) 和 (d) 所示, RMSE 和 MAPE 均在 150 次时取得最小值。

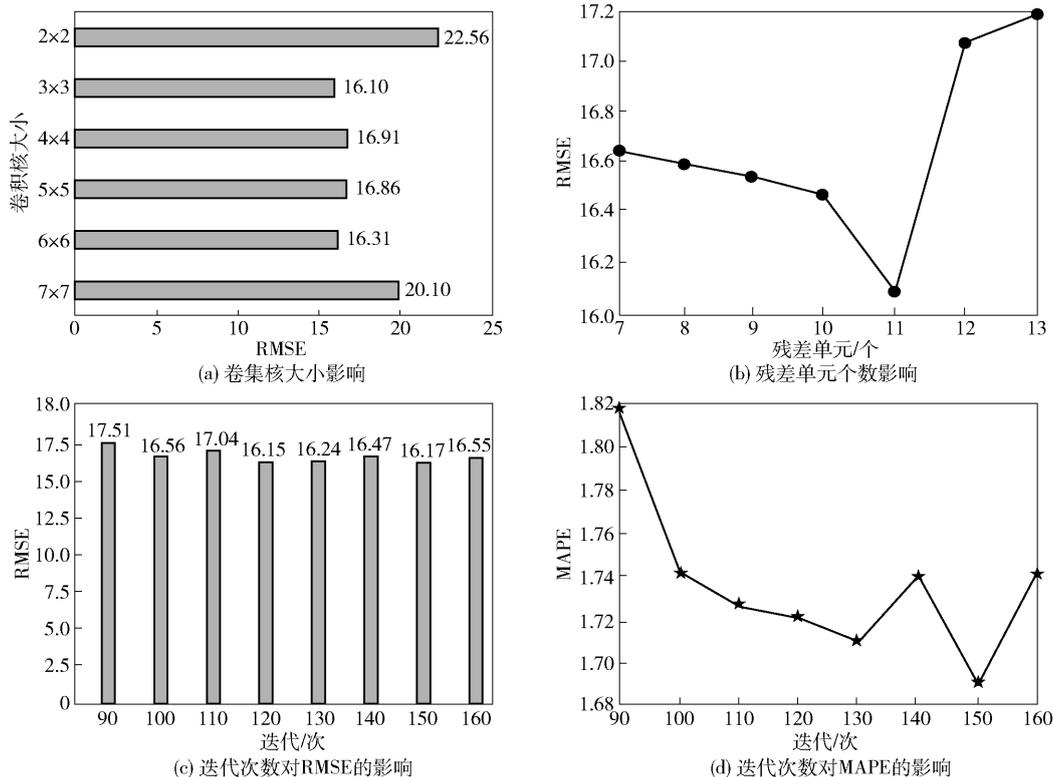


图 5 超参数影响

### 3.4 实验结果

将提出的 CNN-ResNet-LSTM 模型与其他模型进行了比较,如表 2 所示. 从预测结果来看,模型 ARIMA 和循环神经网络 (SimpleRNN, GRU, LSTM) 对最终流量的预测误差比较大,由于提出的 CNN-ResNet-LSTM 模型充分考虑了交通流量的时空特

征,所以 CNN-ResNet-LSTM 模型与其他 6 个模型在交通流量的短时预测相比,表现出了较好的结果,其 RMSE 值为 16.10, MAPE 值为 1.699. 从模型复杂程度上看, CNN-ResNet-LSTM 模型在保证较好预测结果的基础上大大降低了模型的复杂程度,其参数数量为 281 054.

表 2 实验结果对比

模型	模型参数	参数数量	RMSE	MAPE
ARIMA	无	无	20.29	4.370
CNN	2 层 CNN, 参数与 CNN-ResNet-LSTM 相同	42 784	20.38	2.179
CNN	3 层 CNN, 参数与 CNN-ResNet-LSTM 相同	153 568	19.51	2.070
SimpleRNN	3 层 SimpleRNN, 参数与 CNN-ResNet-LSTM 相同	5 666	99.93	13.980
GRU	3 层 GRU, 参数与 CNN-ResNet-LSTM 相同	16 866	80.98	13.719
LSTM	3 层 LSTM, 参数与 CNN-ResNet-LSTM 相同	22 466	74.15	14.020
ConvLSTM	2 层 ConvLSTM, 参数与 CNN-ResNet-LSTM 相同	550 002	18.65	2.030
ST-ResNet <sup>[13]</sup>	2 层 CNN, 参数与 CNN-ResNet-LSTM 相同	2 266 528	16.69	1.910
CNN-ResNet-LSTM	—	281 054	16.10	1.699

## 4 结束语

提出了一种新的能够对短时交通流量进行准确

预测的组合学习模型 CNN-ResNet-LSTM, 可根据历史轨迹数据, 结合外部因素对城市各个区域交通流量的变化进行预测. 该模型将卷积神经网络与长短

期记忆循环神经网络集成到一个端到端的网络框架,分别捕获城市交通流量数据的局部空间特征和长依赖性之间的相关特征,并通过增加残差神经单元个数加深网络深度,以提高模型的预测准确性。为了验证模型的性能,利用北京市出租车 GPS 数据对模型进行了评估,并通过与多个常用的预测方法 (ARIMA, CNN, BasicRNN, LSTM, GRU, ST-ResNET, ConvLSTM) 进行比较,证实了提出的模型拥有较高的准确性。因只按照经纬度将北京市进行网格划分,并未考虑交通路网的复杂性,下一步的研究将考虑复杂的交通路网信息,对具体的路段和地区进行分类研究,同时对其他城市的数据进行分析,从而增强模型的泛化能力,提高算法的普适性。

### 参考文献:

- [1] 陈湘军, 阮雅端, 陈启美, 等. 车辆图像稀疏特征表示及其监控视频应用[J]. 北京邮电大学学报, 2016 (S1): 81-86.  
Chen Xiangjun, Ruan Yaduan, Chen Qimei, et al. Sparse feature representation of vehicle images and its surveillance video application [J]. Journal of Beijing University of Posts and Telecommunications, 2016 (S1): 81-86.
- [2] Zhang Nan, Wang Feiyue, Zhu Fenghua, et al. DynaCAS: computational experiments and decision support for ITS[J]. IEEE Intelligent Systems, 2008, 23(6): 19-23.
- [3] Sun Bin, Cheng Wei, Goswami Prashant, et al. Short-term traffic forecasting using self-adjusting  $k$ -nearest neighbours[J]. IET Intelligent Transport Systems, 2017, 12(1): 41-48.
- [4] Castro-Neto M, Jeong Y S, Jeong M K, et al. Online-SVR for short-term traffic flow prediction under typical and atypical traffic conditions[J]. Expert Systems with Applications, 2009, 36(3): 6164-6173.
- [5] Schmidhuber J. Deep learning in neural networks: an overview[J]. Neural Networks, 2015, 61: 85-117.
- [6] Huang Wenhao, Song Guojie, Hong Haikun, 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.
- [7] Lu Wenqi, Luo Dongyu, Yan Menghua. A model of traffic accident prediction based on convolutional neural network[C]//2017 2nd IEEE International Conference on Intelligent Transportation Engineering (ICITE). Singapore: IEEE, 2017: 198-202.
- [8] Zhao Zheng, Chen Weihai, Wu Xingming, et al. LSTM network: a deep learning approach for short-term traffic forecast[J]. IET Intelligent Transport Systems, 2017, 11(2): 68-75.
- [9] Bates J M, Granger C W J. The combination of forecasts [J]. Journal of the Operational Research Society, 1969, 20(4): 451-468.
- [10] Shi Xingjian, Chen Zhouong, Wang Hao, et al. Convolutional LSTM network: a machine learning approach for precipitation nowcasting[C]//Advances in Neural Information Processing Systems. Montreal: Neural Information Processing Systems Foundation, 2015: 802-810.
- [11] 段宗涛, 张凯, 杨云, 等. 基于深度 CNN-LSTM-ResNet 组合模型的出租车需求预测[J]. 交通运输系统工程与信息, 2018, 18(4): 215-223.  
Duan Zongtao, Zhang Kai, Yang Yun, et al. Taxi demand prediction based on deep CNN-LSTM-ResNet combined model [J]. Journal of Transportation Systems Engineering and Information Technology, 2018, 18(4): 215-223.
- [12] Wu Yuankai, Tan Huachun, Qin Lingqiao, et al. A hybrid deep learning based traffic flow prediction method and its understanding[J]. Transportation Research Part C: Emerging Technologies, 2018, 90: 166-180.
- [13] He Kaiming, Zhang Xiangyu, Ren Shaoqing, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE Computer Society, 2016: 770-778.