

Journal of System Simulation

Volume 36 | Issue 2

Article 16

2-15-2024

Short-term Bus Passenger Flow Prediction Based on Convolutional Long-short-term Memory Network

Jing Chen

School of Information Technology and Engineering, Tianjin University of Technology and Education, Tianjin 300222, China, c_j_223@163.com

Zhaochong Zhang

School of Information Technology and Engineering, Tianjin University of Technology and Education, Tianjin 300222, China, s789658@qq.com

Linkai Wang

School of Information Technology and Engineering, Tianjin University of Technology and Education, Tianjin 300222, China

Mai An

Smart City Development Authority, Sino-Singapore Tianjin Eco-city Management Committee, Tianjin 300467, China

See next page for additional authors

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>

 Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation. For more information, please contact xtfzxb@126.com.

Short-term Bus Passenger Flow Prediction Based on Convolutional Long-short-term Memory Network

Abstract

Abstract: To address the problem that the traditional short-time passenger flow prediction method does not consider the temporal characteristics similarity between the inter-temporal passenger flows, a shorttime passenger flow prediction model k-CNN-LSTM is proposed by combining the improved k-means clustering algorithm with the CNN and the LSTM. The k-means is used to cluster the intertemporal timeseries data, the k-value is determined by using the gap-statistic, and a traffic flow matrix model is constructed. A CNN-LSTM network is used to process the short-time passenger flows with spatial and temporal characteristics. The model is tested and parameter tuned by the real dataset. The test results show the model is able to predict the spatially correlated data more accurately.

Keywords

CNN, LSTM, spatiotemporal data prediction, k-means clustering, passenger flow prediction

Authors

Jing Chen, Zhaochong Zhang, Linkai Wang, Mai An, and Wei Wang

Recommended Citation

Chen Jing, Zhang Zhaochong, Wang Linkai, et al. Short-term Bus Passenger Flow Prediction Based on Convolutional Long-short-term Memory Network[J]. Journal of System Simulation, 2024, 36(2): 476-486.

基于卷积长短时记忆网络的短时公交客流量预测

陈静¹, 张昭冲^{1*}, 王琳凯¹, 安脉², 王伟¹

(1. 天津职业技术师范大学 信息技术工程学院, 天津 300222; 2. 中新天津生态城管委会 智慧城市发展局, 天津 300467)

摘要: 针对传统的短时客流预测方法没有考虑到时序特征中跨时段客流之间的相似性问题, 提出一种改进 *k-means* 聚类算法与卷积神经网络和长短时记忆网络相结合的短时客流量预测模型 *k-CNN-LSTM*。通过 *k-means* 算法对跨时段时序数据进行聚类, 使用间隔统计确定 *k* 值, 构建交通流矩阵模型, 采用 *CNN-LSTM* 网络处理具有时空特征的短时客流。该模型能够对具有空间相关性的数据进行较为准确的预测。使用真实数据集对模型进行检验和参数调优, 实验结果表明: *k-CNN-LSTM* 模型较其他模型有相对较高的预测精度。

关键词: 卷积神经网络; 长短时记忆网络; 时空数据预测; *k-means* 聚类; 客流量预测

中图分类号: TP181 文献标志码: A 文章编号: 1004-731X(2024)02-0476-11

DOI: 10.16182/j.issn1004731x.joss.22-1168

引用格式: 陈静, 张昭冲, 王琳凯, 等. 基于卷积长短时记忆网络的短时公交客流量预测[J]. 系统仿真学报, 2024, 36(2): 476-486.

Reference format: Chen Jing, Zhang Zhaochong, Wang Linkai, et al. Short-term Bus Passenger Flow Prediction Based on Convolutional Long-short-term Memory Network[J]. Journal of System Simulation, 2024, 36(2): 476-486.

Short-term Bus Passenger Flow Prediction Based on Convolutional Long-short-term Memory Network

Chen Jing¹, Zhang Zhaochong^{1*}, Wang Linkai¹, An Mai², Wang Wei¹

(1. School of Information Technology and Engineering, Tianjin University of Technology and Education, Tianjin 300222, China;

2. Smart City Development Authority, Sino-Singapore Tianjin Eco-city Management Committee, Tianjin 300467, China)

Abstract: To address the problem that the traditional short-time passenger flow prediction method does not consider the temporal characteristics similarity between the inter-temporal passenger flows, a short-time passenger flow prediction model *k-CNN-LSTM* is proposed by combining the improved *k-means* clustering algorithm with the CNN and the LSTM. The *k-means* is used to cluster the intertemporal time-series data, the *k*-value is determined by using the gap-statistic, and a traffic flow matrix model is constructed. A CNN-LSTM network is used to process the short-time passenger flows with spatial and temporal characteristics. The model is tested and parameter tuned by the real dataset. The test results show the model is able to predict the spatially correlated data more accurately.

Keywords: CNN; LSTM; spatiotemporal data prediction; *k-means* clustering; passenger flow prediction

0 引言

低碳环保是未来生态城市的理想发展模式,
城市公共交通系统是城市综合交通系统的主导。

公交线路各站点的客流呈现出分布不均衡的特点^[1], 当客流量较大时, 来往车辆较多, 会造成交通拥堵, 对公交车进出站时间造成影响。客流量

收稿日期: 2022-10-04 修回日期: 2022-12-08

基金项目: 天津市教委科研计划(2021KJ008)

第一作者: 陈静(1984-), 女, 副教授, 硕士生导师, 博士, 研究方向为机器学习。E-mail: c_j_223@163.com

通讯作者: 张昭冲(1999-), 男, 硕士生, 研究方向为时空数据预测。E-mail: s789658@qq.com

相较小, 又无法满足公交车的满载率。由此可见, 一旦某个站点的客流量出现异常, 就会对公交线路上的其他站点造成严重影响。所以构建可靠的公交客流预测模型对于优化线路、节省能源具有重要意义。

目前, 运用到短时客流的预测方法主要有数理统计模型, 如卡尔曼滤波模型、灰色模型等; 人工智能模型, 如BP神经网络、SVR回归模型、LSTM等; 基于以上模型的组合模型, 如灰色模型组合马尔可夫模型、LSTM组合SVR模型等。在数理统计模型中, 赵鹏等^[2]使用自回归移动平均模型对轨道交通客流进行预测; 张春辉等^[3]使用卡尔曼滤波方法对公交的短时客流进行预测。数理统计模型能够很好地描述客流变化趋势, 但以上模型对于非线性、随机性较强的客流预测精度较差。在人工智能模型中, Yang^[4]使用SVR回归模型, 通过遗传算法对回归参数进行优化, 能够有效对短时客流的非线性特征进行捕捉; 刘欣彤等^[5]使用SVM-KNN预测带有影响因素下的公交客流; Chen等^[6]证明了LSTM模型能够有效地适用于短期客流量预测, 克服因数据时间间隔过长导致的历史信息遗忘; 戴晓峰等^[7]使用BP神经网络对交通流数据进行预处理, 使用LSTM捕获历史交通流量的时序特征, 将模型的输出结果输入到SVR进行交通流量预测。相比单一模型, 组合模型可以对特征进行多次提取, 刘明宇等^[8]通过使用门控循环单元(GRU)进行交通流量预测, 并使用交叉验证方法确定最佳门控单元个数, 虽然能够避免因数据的时间跨度较长而导致的信息遗忘, 但该模型忽略了站点与站点之间的空间关联; Zhao等^[9]使用起点—目的地相关性矩阵(origin destination correlation, ODC)表示不同路段之间的联系; CNN^[10-11]发现相邻路口之间的空间关联, CNN有局部感知、权重共享等特点, 相比于ODC矩阵, CNN避免了许多复杂操作, 不需要人为地对空间分布进行预处理, 且不需要进行额外的特征抽取; CNN+LSTM^[10-11]可以更好地捕

捉客流的时空特征; 龚兰兰等^[12]使用CNN+GRU对公交短时客流进行预测; 王祥雪等^[13]使用LSTM-RNN模型, 根据交通流的时空相关性完成时间序列的重构。但以上模型忽略了客流在时序上的隐式特征, 且以上研究主要集中在公交客流的日变化规律, 未能注意到一天中的跨时段客流反映出的更短时间间隔的变化规律。如客流在运营时段内的分布不均衡而形成断面客流之间的相似性^[14]。Li等^[15]通过使用k-means聚类方法将统一时间范围内交通状态相同的区域进行聚类, 通过设定损失函数确定最佳聚类数。在光伏功率预测领域, 陈振祥等^[16]使用CNN挖掘气象参数之间的内相关性, 使用LSTM挖掘历史光伏功率的时序信息, 并使用k-means++对历史数据进行分类, 使用轮廓系数确定最佳聚类数量, 使历史数据具有各自独特的功率标签, 提高了输出功率的预测精度, 但轮廓系数在确定聚类数量时花费时间较长, 不利于对时间间隔较长的历史客流数据进行聚类。

因此, 本文提出k-CNN-LSTM模型对公交短时客流量进行预测, 使用k-means对客流量变化趋势相同的时段进行聚类, 使用间隔统计^[17]直接获取最佳聚类值, 避免手动赋值, 从而快速提高模型的预测精度。将聚类标签与CNN提取的公交站点间的空间特征进行融合, 再使用LSTM提取历史客流的时序特征, 并将该方法在真实客流数据集中进行实验研究。

1 基于k-CNN-LSTM模型的时空交通流预测

1.1 交通流矩阵构造

公交车站作为流量密集区, 每个站点的客流量会受该站点历史客流与相邻站点客流的影响, 故对目标站点的客流预测涉及到对空间特征以及时间序列特征的提取。本文利用CNN+LSTM提取时空特征, 如图1所示。

城市公交站点多以网格状分布，使用网格划分的方法对公交客流量进行统计，且保证网格足够小，使每个网格中最多有一个站点，没有公交站点的网格位置客流量默认为0，由划分的网格可得到 n 行 m 列的矩阵，矩阵中 $x_t^{(i,j)}$ 表示时隙 t ，站点坐标为 (i,j) 的客流量，其中， $0 \leq i \leq n$ ， $0 \leq j \leq m$ 。在时序上，本文通过前几个时段的客流来预测当前时段的客流，建立时空矩阵：

$$\mathbf{D}_t = \begin{bmatrix} x_t^{(0,0)} & x_t^{(0,1)} & \cdots & x_t^{(0,m)} \\ x_t^{(1,0)} & x_t^{(1,1)} & \cdots & x_t^{(1,m)} \\ \vdots & \vdots & & \vdots \\ x_t^{(n,0)} & x_t^{(n,1)} & \cdots & x_t^{(n,m)} \end{bmatrix} \quad (1)$$

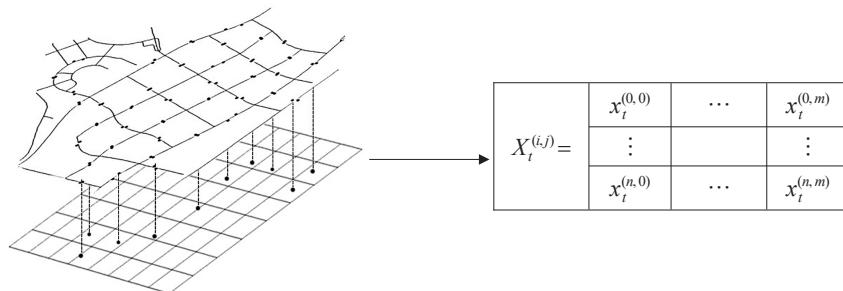


图1 公交站点的网格划分
Fig. 1 Gridding of bus stops

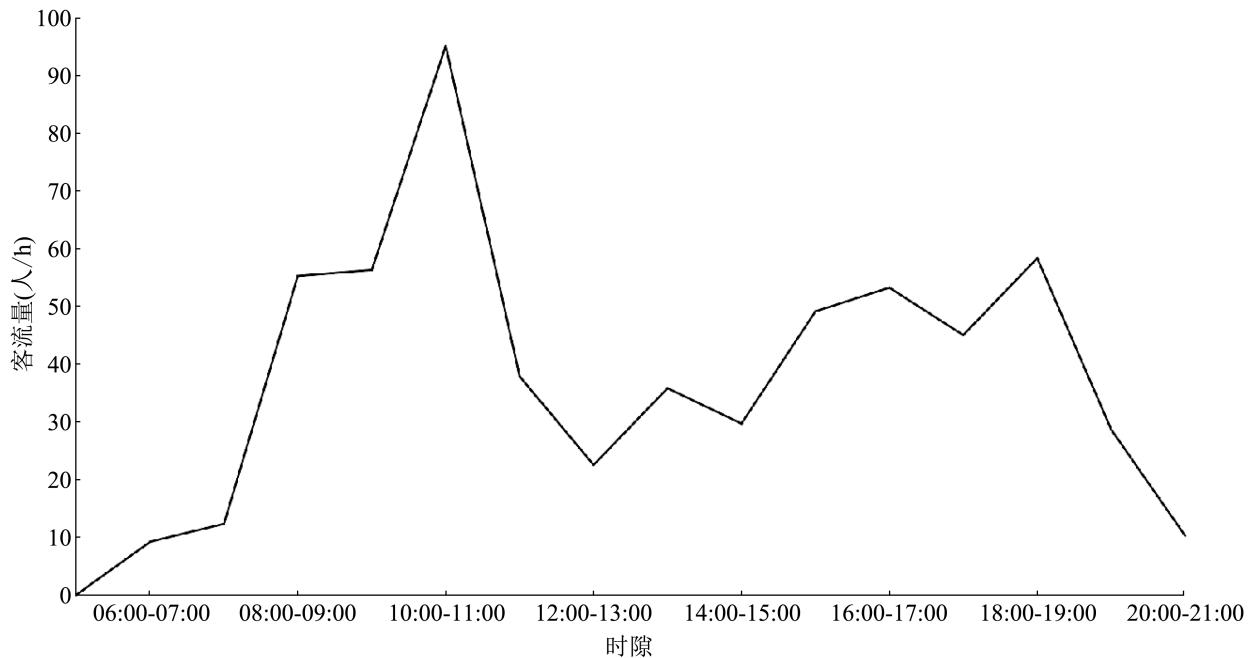


图2 公交车运营时段客流量
Fig. 2 Passenger flow during bus operation

式中： l 为间隔时隙的个数； $x_t^{(i,j)}$ 为第 t 时隙处于位置 (i,j) 的站点的客流量。

1.2 跨时段聚类标签

公交车站点的客流量除了受到临近时刻客流影响之外，也受到跨时段客流之间的影响^[18]，以天津中新生态城商业街站点为例，该站点公交车某一天运营时段内以1 h为最小时隙的客流量如图2所示，可见07:00—8:00与09:00—10:00的客流量具有相同的上升趋势，10:00—11:00、18:00—21:00的客流量具有相同的下降趋势。

为了提取跨时段客流之间的相似性，提高模型的预测精度，本文使用 k-means 对跨时段的客流进行聚类，传统的 k-means 聚类算法需要手动设定初始 k 值，且初始质心随机选取，容易陷入局部最优。本文使用间隔统计确定 k 值，通过计算每个聚类时段中两两观测值之间的欧氏距离平方和，然后以零均值均匀分布所得的聚类结果为参照进行 k 值调整，以确定最佳聚类数目。具体过程如算法 1 所示。

算法 1：基于 k-means 方法的跨时段客流聚类数值确定

输入：目标站点的坐标位置为 (a, b) ，获取目标站点所有时段的真实客流作为输入， $\{f_m^1, f_m^2, \dots, f_m^n\}$ 为第 m 个时段的 n 个特征，数据总长度为 l ，可选的聚类数为 $\{1, 2, \dots, k\}$

输出：最佳聚类数
for $k=1, 2, \dots, K$
 k-means 获取质心 $[C_1, C_2, \dots, C_k]$ ，聚类标签 $[c_1, c_2, \dots, c_l]$

计算输入数据与其所在聚类质心 C_c 的距离之和 W_k (D 为计算数据特征与质心的欧氏距离)

$$W_k = \sum_{m=1}^l D(\{f_m^1, f_m^2, \dots, f_m^n\}, \{C_c^1, C_c^2, \dots, C_c^n\})$$

for $j=1, 2, \dots, B$ ，其中， B 为蒙特卡洛模拟次数

均匀分布随机产生与原始样本数一样多的随机样本 $R=\{r_m^1, r_m^2, \dots, r_m^n\}$

使用 k-means 方法获取随机样本 R 的质心 $[\alpha_1, \alpha_2, \dots, \alpha_k]$ ，聚类标签 $[\zeta_1, \zeta_2, \dots, \zeta_l]$

随机样本与质心的距离之和为

$$W_k^j = \sum_{m=1}^l D(\{r_m^1, r_m^2, \dots, r_m^n\}, \{\alpha_1^1, \alpha_1^2, \dots, \alpha_1^n\})$$

end for

损失差值 $G=E(\ln W_k)-\ln W_k$

$S_k = \sqrt{1+1/B} \times \tau(\ln W_k)$ ， τ 为计算对数处理后抽样值的标准差

if $G_{k-1}-G_k+S_k>0$

返回满足条件的最小 k 值

end if

end for

1.3 CNN

CNN 作为一种前馈式网络^[19]，已经在图像分类、自然语言处理等领域取得显著成果。CNN 作为多层次监督学习网络，多用来处理网格数据，如图像数据、时间序列数据，客流数据属于时间序列数据^[20]，且一维 CNN 可以提取时间序列的特征，故先对交通流矩阵进行降维处理，用 $x_t^{m \times i+j}$ 表示 t 时隙时，站点坐标为 (i, j) 的客流量，使用一维 CNN 捕捉公交站点与站点之间的空间关联。

一维 CNN 流程图如图 3 所示，CNN 包含 2 个特殊的神经网络层：

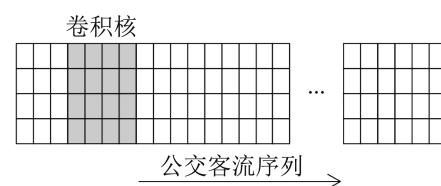


图3 一维卷积流程图
Fig. 3 1D convolution process

(1) 卷积层

卷积层与输入数据相连，在时序方向上进行局部特征的提取。

$$x_l^j = f \left(\text{Conv 1D} \left(\sum (x_{l-1}^i \times w_l^j + b_l^i) \right) \right) \quad (2)$$

式中： x_l^j 为卷积后的输出数据； f 为非线性激活函数；Conv 1D 为一维卷积操作； x_{l-1}^i 为输入数据； w_l^j 为该层卷积核中的权重值； b_l^i 为该层的偏置值； l 为时序长度； i 和 j 为卷积过程中对应的位置。

(2) 池化层

池化层可以对卷积得到的局部特征进行二次采样，且池化层不需要保留参数，有利于减少计算量和特征数量，最后通过全连接操作得到输出结果。

$$x_{l+1}^j = \text{polling}(x_l^j) \quad (3)$$

式中：polling 为池化操作，本文选择 max-pooling 进行池化操作； x_{l+1}^j 为二次采样后的输出。

1.4 LSTM

传统的RNN模型可用于处理时间序列，RNN将一部分输出值继续作为下一时刻的隐层数据，但RNN的记忆周期较短，且只经过单一激活函数，若时序数据的间隔较长，RNN中的信息传递将会逐渐衰减，可能会出现梯度消失和梯度爆炸^[21]。LSTM在此基础上使用了遗忘门、输入门、输出门，可以避免上述问题，结构如图4所示。

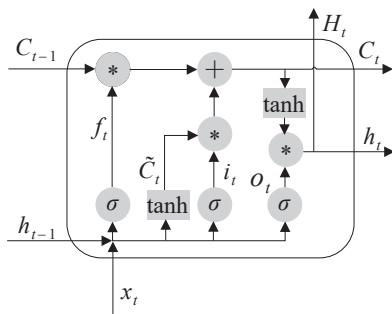


图4 LSTM结构图
Fig. 4 Structure diagram of LSTM

遗忘门用于选择性保留上一时刻记忆单元 C_{t-1} 中的部分信息，输入门用于选择性保留当前时刻输入数据 x_t 的信息，并更新当前的记忆单元 C_t ，输出门用于输出下一时刻的隐层信息 h_t 。遗忘门 f_t 、输入门 i_t 、记忆单元的输入状态 \tilde{C}_t 和更新记忆单元 C_t :

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (4)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (5)$$

$$\tilde{C}_t = \tanh(W_C[h_{t-1}, x_t] + b_C) \quad (6)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (7)$$

式中：“*”为Hadamard乘积；“[]”为数值拼接； W_f 、 W_i 、 W_C 、 b_f 、 b_i 、 b_C 分别为遗忘门、输入门和记忆单元的权重和偏置值； σ 为sigmoid函数； \tanh 为双曲正切函数。

输出门和隐层输出为

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (8)$$

$$h_t = o_t * \tanh(C_t) \quad (9)$$

式中： W_o 为输出门的权重； b_o 为偏置值。

1.5 k-CNN-LSTM模型

k-CNN-LSTM模型结构如图5所示。

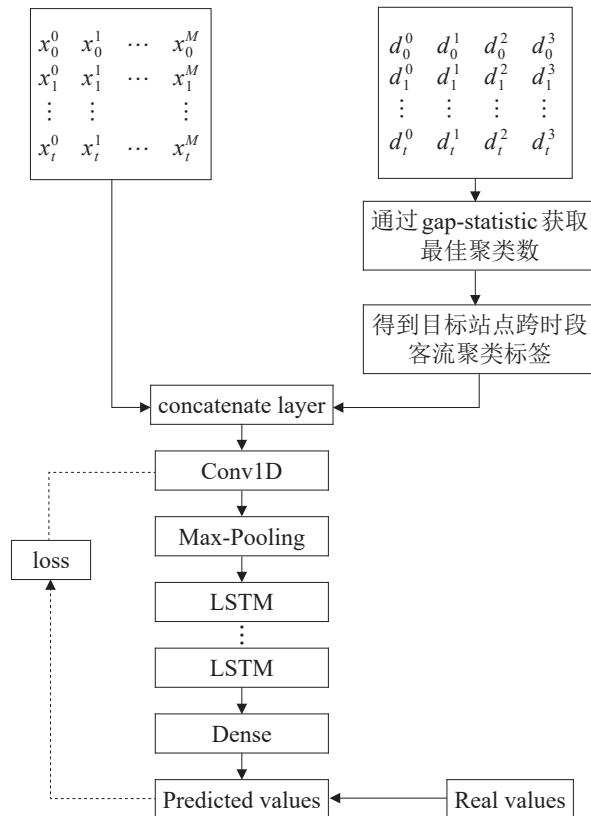


图5 k-CNN-LSTM模型结构框架
Fig. 5 Model Structure Framework of k-CNN-LSTM

在网格中输入数据 x_t^M ，即位于 (i,j) 的公交站点在 t 时段内的车流量。其中， $M=m \times i+j$ ， (i,j) 为公交站点的位置坐标， t 表示时段。为了捕捉跨时段客流之间的相似性，以1 h为一组数据，在1 h内，每隔15 min统计一次目标站点的客流量，记录1 h内客流的最大值、最小值、平均值和标准差 d_t^0 、 d_t^1 、 d_t^2 、 d_t^3 ，将其作为聚类时该时段的特征。

预测过程如下。

step 1：以 d_t^i 为输入数据，使用Gap-Statistic得到最佳聚类簇数 k' ；

step 2：以 k' 作为k-means聚类算法的初始聚类数进行聚类，得到目标站点跨时段客流的聚类标签，然后与 x_t^M 经过concatenate层进行特征合并；

step 3：对合并后的数据进行一维卷积处理，

提取公交站点与站点间的空间关联，然后通过池化进行二次采样；

step 4：将池化后的数据经LSTM处理后得到预测值；

step 5：由预测值与真实值得到误差loss进行反向传播，更新网络权值，然后重复step 3~5，直到loss稳定小于某一阈值或达到最大训练次数后停止循环。

k-CNN-LSTM模型内部结构如图6所示。

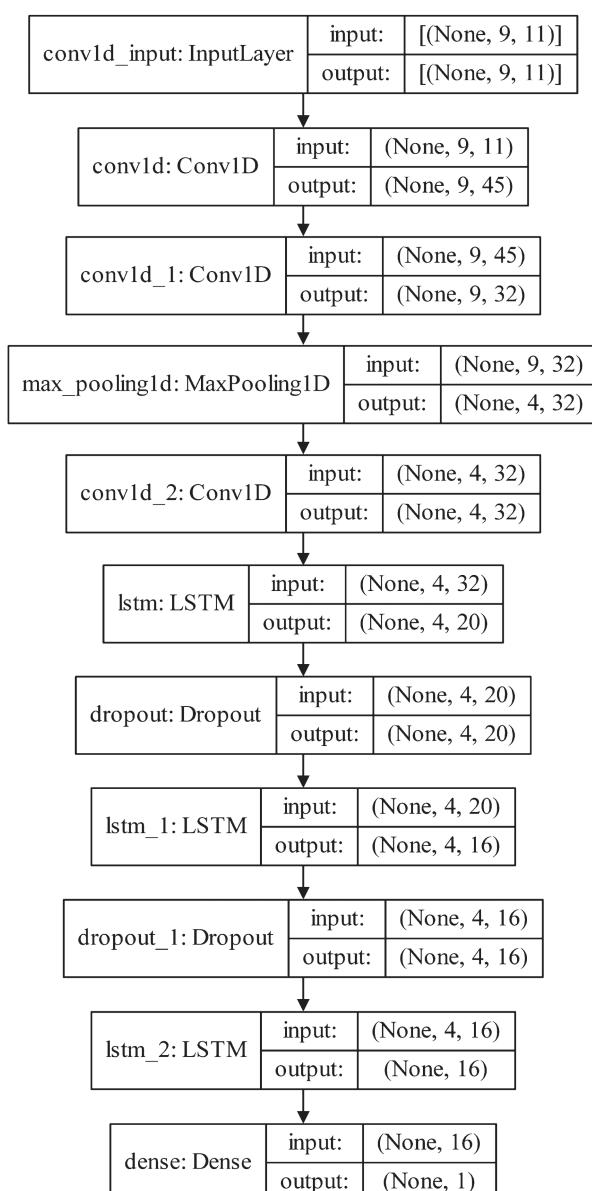


图6 k-CNN-LSTM模型内部结构图

Fig. 6 Internal structure diagram of k-CNN-LSTM

2 实验研究

2.1 数据来源描述

本研究的数据来自天津市滨海新区中新天津生态城，数据内容为2020-09-01—10-31的5条线路，176个公交站点的客流量，数据总记录数为430 834条，删除数据中的异常值、空值。本实验研究的时间范围为05:00—21:00，以1 h为最小单位对每个站点的客流量进行统计。

研究区域内有3条线路经过商业街站，来往乘客大多为居民、上班或换乘人员，如图7所示。对商业街站点近5日运营时段的客流量进行分析，如图8所示。商业街站的客流量分布周期性明显，故将商业街站作为本次研究的目标站点。为了避免单一性，验证模型的泛化能力，除了选取生态城商业街为目标站点之外，另外选取3条线路中的服务中心站与第三社区中心站进行对比研究。

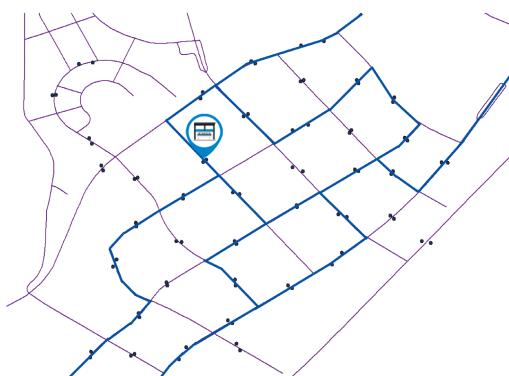


图7 公交线路图
Fig. 7 Route map of public transport vehicles

2.2 评价指标

为了评估模型预测结果的准确程度，本实验采用均方误差、平均绝对误差与对称平均绝对百分比误差对预测结果进行评估：

$$E_{MS} = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (10)$$

$$E_{MA} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (11)$$

$$E_{\text{SMAP}} = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{(|\hat{y}_i| + |y_i|)/2} \times 100\% \quad (12)$$

式中: \hat{y}_i 为目标公交站点客流的预测值; y_i 为实际目标公交站点客流的真实值; n 为按时段划分后的数据个数。

2.3 空间相关性分析

在研究客流问题时, 站点与站点之间往往存在空间关联性, 因此, 在图7中选择从商业街站出发, 将商业街站点与1 h内可以到达的所有站点进行客流的相似性分析。

在分析交通流量空间特性时, 皮尔逊相关系数常用于度量不规范变量间的相关程度, 故使用皮尔逊相关系数对网格中站点间的客流相似性进行分析:

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (13)$$

式中: i 为时段; X_i , Y_i 分别为第 i 个时段内, 站点 X 与站点 Y 的客流量; n 为时段总数量。

对所有公交站点之间的客流量进行分析, 图9为目标站点商业街站与其他各站点的相关系数。

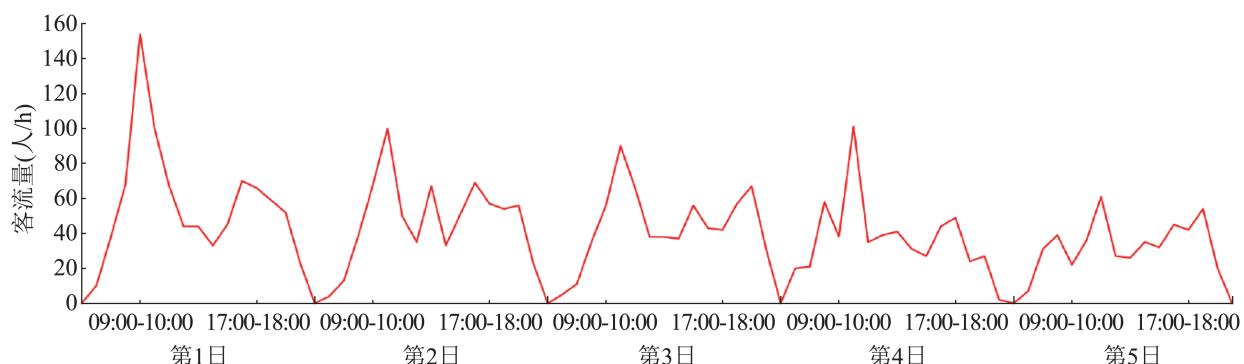


图8 商业街站客流量
Fig. 8 Passenger flow of commercial street station

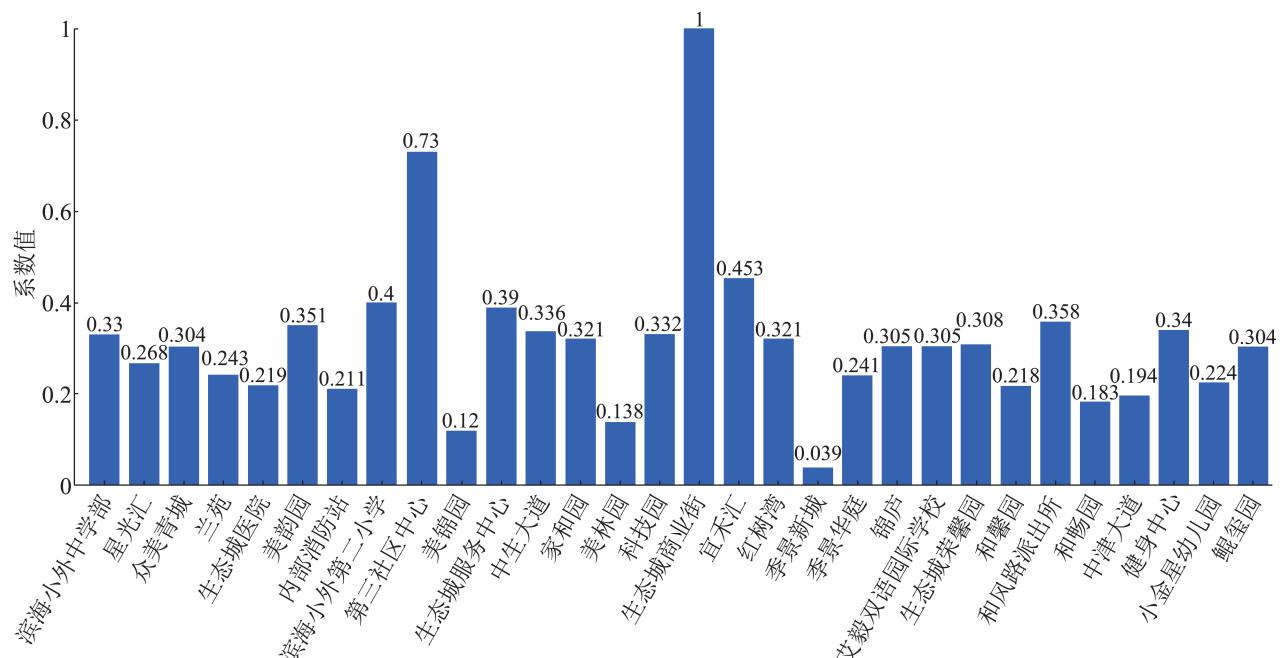


图9 商业街站与其他站点的皮尔逊相关系数
Fig. 9 Pearson correlation coefficient between commercial street station and other stations

根据皮尔逊相关系数的取值范围, 数值在0.2以下的站点之视为无相关; 取值范围在[0.2, 0.4)视为弱相关; [0.4, 0.6)视为中等程度相关; [0.6, 0.8)以上视为强相关; 0.8及以上视为极强相关。

2.4 模型参数设定

使用k-CNN-LSTM模型与传统模型进行比较, 本文模型与对比模型的参数设置如表1所示, 参数名称B为Batchsize, 代表一次训练所包含的步长, Batchsize过大会影响模型的训练速度和优化速度, 降低模型的泛化能力, 过小导致特征提取不足, 本文经前期测试, 最终设定Batchsize为128; E为Epoch, 代表最大训练次数, 本文选择300为最大迭代次数; OPT为优化器; LR为学习率, 直接影响到模型的收敛情况; A为激活函数, 本文采用ReLU作为激活函数; LOSS为损失函数, 选择MSE为模型评价标准。SVR模型中, 核函数选择高斯核函数, 交叉验证参数(CV)选择十折交叉验证。

2.5 实验结果与分析

使用本文提出的方法确定最佳聚类数量, Gap-statistic算法中蒙特卡罗的模拟次数经过前期的实验, 取为300时聚类数值趋于稳定。图10~12分别为算法在聚类过程中的观测值 $\ln W_k$, 参考模拟值 $E(\ln W_k)$, 差值 G_k 以及 $G_{k-1} - G_k + S_k$ 的值随聚类数 k 的变化情况, 由图12可知, 当 k 为7时, $G_{k-1} - G_k + S_k > 0$, 且 k 值最小, 故最佳聚类数为7, 即可将一天中的时段分为7类。

由图9可知, 不考虑相关系数在0.2以下的站点, 分析目标站点与 n 个相邻站点的空间相关性, 由前期的实验测得 n 为10时, 预测误差最小, 故选择相关系数较高的10个站点对目标站点进行预测。

使用k-CNN-LSTM模型与传统模型进行比较, 模型的预测结果如图13所示, 模型的评价如表2所示, 两者结合可知k-CNN-LSTM的预测效果要优于其他模型。

表1 模型训练参数
Table 1 Training parameters of model

模型名称	参数名称	参数值
k-CNN-LSTM	B/E/OPT/LR/A/LOSS	128/300/Adam/0.01/ReLU/MSE
CNN-LSTM	B/E/OPT/LR/A/LOSS	128/300/Adam/0.01/ReLU/MSE
BiLSTM	B/E/OPT/LR/LOSS	128/300/Adam/0.01/MSE
LSTM	B/E/OPT/LR/LOSS	128/300/Adam/0.01/MSE
SVR	Kernel/CV/LOSS	Rbf/10/MSE

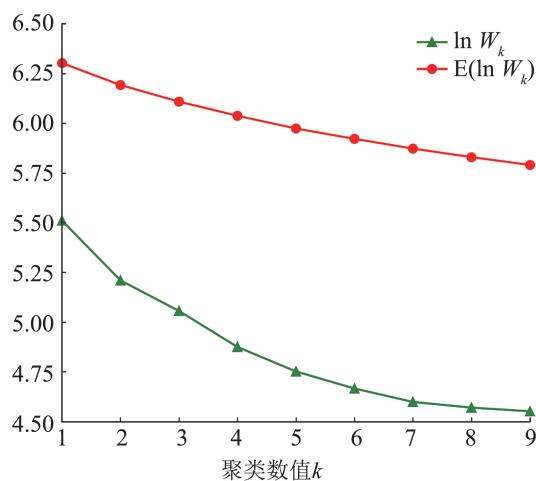


图10 $\ln W_k$ 与 $E(\ln W_k)$ 随 k 值的变化图
Fig. 10 Variation of $\ln W_k$ and $E(\ln W_k)$ with k

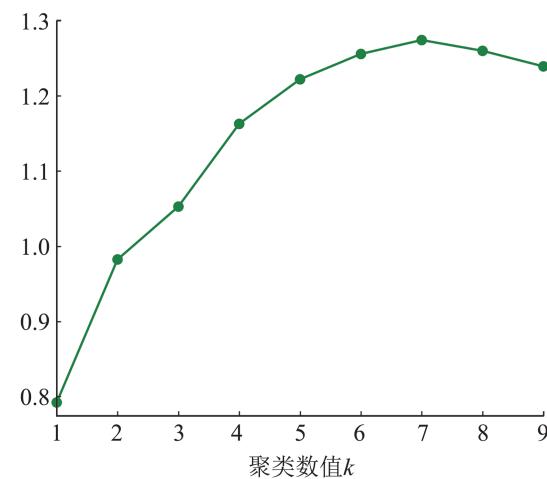
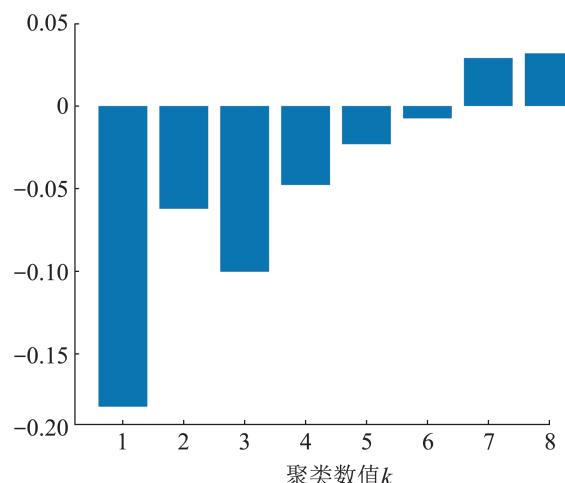
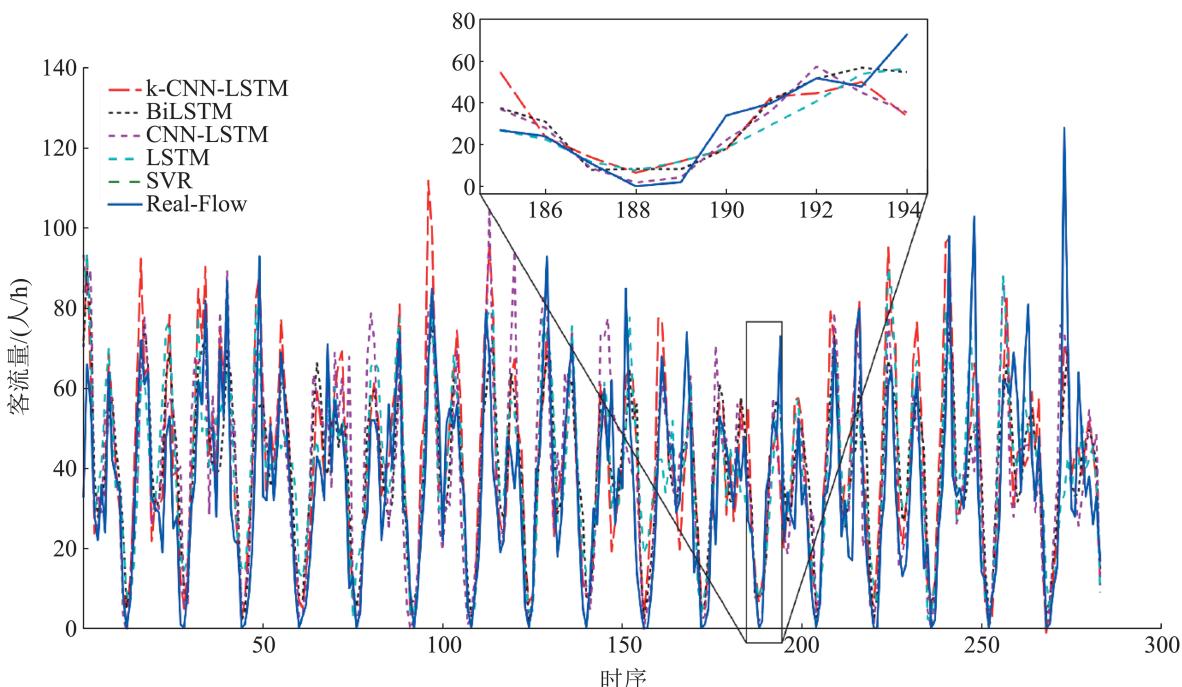


图11 差值 G 随 k 值的变化图
Fig. 11 Variation of G with k

图12 $G_{k-1}-G_k+S_k$ 的值随 k 值的变化图
Fig. 12 Variation of $G_{k-1}-G_k+S_k$ with k

对于商业街站点，CNN-LSTM 捕捉了站点之间的空间关联，相比 LSTM 模型具有较好的预测效果，但相比于本文模型，未考虑到跨时段客流之间的相似性，预测结果较差；Bi-LSTM 与 LSTM 分别从双向和单向进行时间序列的预测，Bi-LSTM 能同时获取向前、向后的时序信息，预测效果相比与 LSTM 较好，但两者均未考虑到站点之间的空间关联，预测结果相比与 k-CNN-LSTM 较差；由于站点客流量的非线性和随机性较强，对于 SVR 模型，除了需要手动调参之外，对于非线性数据，核函数的选择也较为困难，使得 SVR 模型预测结果不如 k-CNN-LSTM 理想。

图13 模型预测结果对比
Fig. 13 Comparison of model prediction results表2 模型预测评价对比
Table 2 Comparison of model evaluation

模型	商业街			服务中心			第三社区中心		
	MSE	MAE	SMAPE/%	MSE	MAE	SMAPE/%	MSE	MAE	SMAPE/%
k-CNN-LSTM	227.48	11.30	45.44	164.60	9.77	45.16	150.44	9.37	47.26
CNN-LSTM	280.55	12.15	48.39	217.99	10.79	49.94	186.23	10.34	50.87
Bi-LSTM	271.56	12.10	48.13	191.76	11.18	54.49	168.11	10.19	48.00
LSTM	311.93	12.67	47.85	198.88	10.85	50.98	283.36	13.68	55.68
SVR	252.74	12.90	50.77	164.93	9.82	45.80	160.00	10.27	49.57

对于其他2个站点, 本文模型预测的MSE、MAE与SMAPE的值与商业街站点较为相近, 且与基础模型相比较小, 具有较强的适应能力。

3 结论

短期客流预测是实现智慧城市智能交通发展的重要一环, 本文针对现有的客流预测仅关注时间与空间特性, 并未挖掘到时序上的深层特征, 提出了k-CNN-LSTM模型进行短期客流预测, 利用Gap-statistic确定最佳聚类数, 利用相关系数得到关联性最大的站点, 经过特征融合, 使用卷积捕获站点之间的空间特征, 使用LSTM捕获时序特征, 通过与捕获时空特征的CNN-LSTM模型与仅捕获时序特征的LSTM模型进行对比, 结果表明: k-CNN-LSTM具有更高的预测精度。因公交车客流量易受天气, 节假日等因素的影响, 下一步可将天气作为一部分输入特征, 区别节假日与非节假日分别对模型进行评估, 使模型具有更高的预测精度和更好的泛化能力。

参考文献:

- [1] 谢振东, 刘雪琴, 吴金成, 等. 公交IC卡数据客流预测模型研究[J]. 广东工业大学学报, 2018, 35(1): 16-22.
Xie Zhendong, Liu Xueqin, Wu Jincheng, et al. A Study of Passenger Flow Prediction Based on IC Card Data[J]. Journal of Guangdong University of Technology, 2018, 35(1): 16-22.
- [2] 赵鹏, 李璐. 基于ARIMA模型的城市轨道交通进站量预测研究[J]. 重庆交通大学学报(自然科学版), 2020, 39(1): 40-44.
Zhao Peng, Li Lu. Prediction of Urban Rail Transit Station Inflows Based on ARIMA Model[J]. Journal of Chongqing Jiaotong University(Natural Science), 2020, 39(1): 40-44.
- [3] 张春辉, 宋瑞, 孙杨. 基于卡尔曼滤波的公交站点短时客流预测[J]. 交通运输系统工程与信息, 2011, 11(4): 154-159.
Zhang Chunhui, Song Rui, Sun Yang. Kalman Filter-based Short-term Passenger Flow Forecasting on Bus Stop[J]. Journal of Transportation Systems Engineering and Information Technology, 2011, 11(4): 154-159.
- [4] Yang Zhenqi. Highway Traffic Accident Prediction Based on SVR Trained by Genetic Algorithm[J]. Advanced Materials Research, 2012, 433-440: 5886-5889.
- [5] 刘欣彤, 黄小龙, 谢秉磊. 基于SVM-KNN的降雨条件下短时公交客流预测[J]. 交通信息与安全, 2018, 36(5): 117-123.
Liu Xintong, Huang Xiaolong, Xie Binglei. A Model of Short-term Forecast of Passenger Flow of Buses Based on SVM-KNN under Rainy Conditions[J]. Journal of Transport Information and Safety, 2018, 36(5): 117-123.
- [6] Chen Quanchao, Wen Di, Li Xuqiang, et al. Empirical Mode Decomposition Based Long Short-term Memory Neural Network Forecasting Model for the Short-term Metro Passenger Flow[J]. PloS one, 2019, 14(9): e0222365.
- [7] 戴晓峰, 戈艺澄. 基于深度学习的节假日高速公路交通流预测方法[J]. 系统仿真学报, 2020, 32(6): 1164-1171.
Ji Xiaofeng, Ge Yicheng. Holiday Highway Traffic Flow Prediction Method Based on Deep Learning[J]. Journal of System Simulation, 2020, 32(6): 1164-1171.
- [8] 刘明宇, 吴建平, 王钰博, 等. 基于深度学习的交通流量预测[J]. 系统仿真学报, 2018, 30(11): 4100-4105, 4114.
Liu Mingyu, Wu Jianping, Wang Yubo, et al. Traffic Flow Prediction Based on Deep Learning[J]. Journal of System Simulation, 2018, 30(11): 4100-4105, 4114.
- [9] 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.
- [10] Cao Miaomiao, Li V O K, Chan V W S. A CNN-LSTM Model for Traffic Speed Prediction[C]//2020 IEEE 91st Vehicular Technology Conference (VTC2020-Spring). Piscataway, NJ, USA: IEEE, 2020: 1-5.
- [11] Toon Bogaerts, Antonio D Masegosa, Juan S Angarita-Zapata, et al. A Graph CNN-LSTM Neural Network for Short and Long-term Traffic Forecasting Based on Trajectory Data[J]. Transportation Research Part C: Emerging Technologies, 2020, 112: 62-77.
- [12] 龚兰兰, 凌兴宏. CNN+GRU公交短时客流预测研究[J]. 现代电子技术, 2021, 44(14): 70-74.
Gong Lanlan, Ling Xinghong. Research on Short-term Bus Passenger Flow Prediction Based on CNN+GRU[J]. Modern Electronics Technique, 2021, 44(14): 70-74.
- [13] 王祥雪, 许伦辉. 基于深度学习的短时交通流预测研究[J]. 交通运输系统工程与信息, 2018, 18(1): 81-88.
Wang Xiangxue, Xu Lunhui. Short-term Traffic Flow Prediction Based on Deep Learning[J]. Journal of Transportation Systems Engineering and Information Technology, 2018, 18(1): 81-88.
- [14] 谢英豪, 江志彬, 徐瑞华. 城市轨道交通断面客流数据

- 可视化分析及优化[J]. 城市轨道交通研究, 2017, 20(1): 69-74.
- Xie Yinghao, Jiang Zhibin, Xu Ruihua. Optimized Visualization Analysis of the Section Passenger Data in Rail Transit Network[J]. Urban Mass Transit, 2017, 20 (1): 69-74.
- [15] Li Runmei, Huang Yinfeng, Wang Jian. Long-term Traffic Volume Prediction Based on K-means Gaussian Interval Type-2 Fuzzy sets[J]. IEEE/CAA Journal of Automatica Sinica, 2019, 6(6): 1344-1351.
- [16] 陈振祥, 林培杰, 程树英, 等. 基于K-means++和混合深度学习的光伏功率预测[J]. 电气技术, 2021, 22(9): 7-13, 33.
- Chen Zhenxiang, Lin Peijie, Cheng Shuying, et al. Photovoltaic Power Prediction Based on K-means++ and Hybrid Deep Learning[J]. Electrical Engineering, 2021, 22(9): 7-13, 33.
- [17] Tibshirani R, Walther G, Hastie T. Estimating the Number of Clusters in a Data Set Via the Gap Statistic[J]. Journal of the Royal Statistical Society Series B: Statistical Methodology, 2001, 63(2): 411-423.
- [18] 陈东洋, 陈德旺, 江世雄, 等. 基于时段客流特征聚类的地铁运营时段划分[J]. 计算机系统应用, 2021, 30(3): 256-261.
- Chen Dongyang, Chen Dewang, Jiang Shixiong, et al. Division of Metro Operation Periods Based on Feature Clustering of Passenger Flow[J]. Computer Systems & Applications, 2021, 30(3): 256-261.
- [19] Chen Ken, Chen Fei, Lai Baisheng, et al. Dynamic Spatio-temporal Graph-based CNNs for Traffic Flow Prediction[J]. IEEE Access, 2020, 8: 185136-185145.
- [20] 孙越. 组合模型在铁路客流量预测中的应用研究[D]. 兰州: 兰州交通大学, 2020.
- Sun Yue. The Applications and Research of Combined Model in Railway Passenger Flow Forecast[D]. Lanzhou: Lanzhou Jiaotong University, 2020.
- [21] 杨丽, 吴雨茜, 王俊丽, 等. 循环神经网络研究综述[J]. 计算机应用, 2018, 38(增2): 1-6, 26.
- Yang Li, Wu Yuxi, Wang Junli, et al. Research on Recurrent Neural Network[J]. Journal of Computer Applications, 2018, 38(S2): 1-6, 26.