

基于时空残差网络的区域客流量预测方法

董丽丽, 柳佳欢, 费城, 张翔

(西安建筑科技大学 信息与控制工程学院, 西安 710055)

摘要: 针对区域客流量波动性强、复杂非线性的特征, 易受到季节性影响, 并且单一神经网络模型无法同时学习时间与空间相关性问题, 通过对区域客流量影响因素分析, 结合残差网络 and 全连接网络, 提出了用于区域客流量预测的改进 Quad-ResNet 模型; Quad-ResNet 模型融合了 4 个残差网络和一个全连接网络, 该模型通过深层次的卷积学习空间相关性, 结合 4 个残差网络学习时间邻近性、相似性、周期性、趋势性, 使用全连接网络学习季节性影响; 将 Quad-ResNet 模型与 LSTM、CNN、ST-ResNet 模型在同一数据集上进行区域客流量预测对比实验, 实验结果表明, Quad-ResNet 模型误差小于其他对比模型, 而且在训练和预测的操作上明显比 LSTM 模型更简便, 更适用于区域客流量预测。

关键词: 区域客流量预测; 残差网络; 全连接网络; 季节性影响

Regional Traffic Prediction Method Based on Spatiotemporal Residual Network

Dong Lili, Liu Jiahuan, Fei Cheng, Zhang Xiang

(School of Information and Control Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China)

Abstract: For the characteristics of Regional traffic (Strong volatility, Complex nonlinearity, Susceptible to seasonal effects), as the single neural network model cannot learn temporal and spatial correlation problems simultaneously. By analyzing the influencing factors of regional tourist flow, combining residual networks with fully connected networks. The author proposes an improved Quad-ResNet model for regional tourist traffic forecasting. The Quad-ResNet model integrates 4 residual networks and a fully connected network, in learning spatial correlation through deep convolution, learning time proximity, similarity, periodicity and trend by combining 4 residual networks, also learning seasonal influencing factors by using a fully connected network. Comparing the Quad-ResNet model with the LSTM, CNN, and ST-ResNet models on the same data set for regional tourist traffic forecasting, the experimental results demonstrate that the deviation of Quad-ResNet model is smaller than other models. Moreover, it is obviously easier to train and forecast than the LSTM model, is more suitable for regional tourist traffic forecasting.

Keywords: regional traffic forecasting; residual network; fully connected network; seasonal effect

0 引言

近年来, 随着我国旅游人数的急剧增长, 旅游景区景点饱和、游客拥挤等问题也日益突显出来, 进而影响游客的出游体验和旅游业发展。因此, 准确地预测区域旅游客流量能够为景区管理者快速决策提供帮助, 从而避免游客聚集, 提高游客的安全性, 进一步推动旅游业的持续发展。

目前, 流量预测的方法较多, 主要分为传统方法和深度学习方法。传统的流量预测方法, 如线性回归法^[1-2]、灰色预测法^[3-4]、ARIMA 法^[5]、人工神经网络^[6-9]等, 这些方

法很难准确预测波动性强、复杂非线性的区域旅游客流量, 并且无法学习空间相关性。

随着深度学习的发展, 研究者将其运用在交通流量^[10-12]、客流量^[13-15]、燃气负荷量^[16]等流量预测上。Y. F. Li 等人^[17]采用长短时记忆神经网络 (LSTM) 方法对旅游流量进行预测, 实验表明 LSTM 方法比自回归集成移动平均 (ARIMA) 模型和反向传播神经网络 (BPNN) 有更好的预测效果, 充分利用了旅游客流量数据的时间维度。但此方法没有利用空间属性, X. Zhan 等人^[18]提出了一种基于卷积神经网络 (CNN) 的交通流预测方法, 使用浮动车的 GPS 轨迹数据来估算全市的交通量。X. Ma 等^[19]提出了一种大规模交通网络速度预测的深度卷积神经网络, 将时空矩阵转换为图像作为 CNN 的输入。可以看出, 单一的神经网络无法充分利用时空数据的多属性特征。J. Zhang 等人提出了一种基于深度学习的时空残差网络模型 ST-ResNet, 使用残差网络来模拟人群流量在时间上的相关性, 将城市划分为均匀的网格并使用 ST-ResNet 模型预测每个地

收稿日期: 2019-10-31; 修回日期: 2019-11-20。

基金项目: 国家自然科学基金 (61701388); 陕西省自然科学基金基础研究计划资助项目 (2018JM6080); 西安市科技局科技创新引导项目 (201805033YD11CG17(1), 201805033YD11CG17(2))。

作者简介: 董丽丽 (1960-), 女, 福建福州人, 硕士生导师, 教授, 主要从事数据挖掘、机器学习等方向的研究。

张翔 (1972-), 男, 陕西咸阳人, 硕士生导师, 副教授, 主要从事增强现实、机器学习等方向的研究。

区人群流入量和流出量^[20-21]。段宗涛等人也将出租车 GPS 数据和天气数据等转化为栅格数据, 结合卷积神经网络、长短时记忆神经网络、残差网络构建了出租车需求预测模型^[22]。

虽然以上方法考虑到了时空数据的多属性问题, 但是, 区域客流量易受季节性影响, 短期相关性更强, 且波动性强。针对以上问题, 本文提出用于区域客流量预测的改进 Quad-ResNet 模型, 利用残差网络模拟时空数据的时间与空间特征, 并且利用全连接网络模拟季节性影响。为了验证方法的可行性, 在陕西省宝鸡市扶风县法门镇真实序列数据集上测试了 Quad-ResNet 模型与 LSTM、CNN、ST-ResNet 模型的性能, 发现 Quad-ResNet 模型性能优于 LSTM、CNN、ST-ResNet 模型。

本文的其余部分组织如下。第一节介绍基于时空残差网络的区域客流量预测方法。第二节讨论了几种选定模型的实验设计和性能。最后, 第三部分是结论。

1 基于时空残差网络的区域客流量预测方法

1.1 区域客流量定义

本文主要利用行人定位数据、天气、节假日数据对区域客流量变化规律进行研究, 预测未来五分钟的区域客流量。通过经度和纬度将旅游景区划分为 $M \times N$ 个网格地图, 其中一个网格地图表示一个区域, 则 t 时刻第 m 行、第 n 列网格的区域客流量 $t_i^{m,n}$ 如式 (1) 所示:

$$h_i^{m,n} = |\{p_i \in (m,n) \wedge p_i \in P\}| \quad (1)$$

式中, P 是 t 时刻旅游景区中行人的位置点集合; p_i 是集合 P 中的一个位置点; $p_i \in (m,n)$ 表示位置点 p_i 在网格 $(m \times n)$ 内; $|\cdot|$ 表示集合的基数。

1.2 区域客流量影响因素分析

1.2.1 空间影响

根据地理学第一定律可知, 任何事物都是与其他事物相关的, 且邻近事物之间的相关性可能更强, 距离越近的事物关联可能越紧密^[23]。因此, 旅游景区相邻区域的客流量会因为人群的运动而相互影响, 即存在空间邻近性。距离较远的区域之间也可能相互影响, 两个相似区域的客流量变化情况呈现出一定的相关性, 即为空间的相似性。

1.2.2 时间影响

旅游景区某一时刻区域客流量会受到前几个时刻的影响, 根据时间间隔的长短可以具体分为邻近性、相似性、周期性、趋势性。

1.2.2.1 邻近性

图 1 为五分钟间隔所有区域总流量折线图, 从中可以看到, 0:00~6:00 客流量较少且逐渐减少, 6:00~12:00 客流量不断增加, 12:30 左右出现当日的一个高峰, 然后不断振荡直到 20:00, 之后客流量开始逐步减少。对于一天各个时刻的客流量来说, 每个时刻的客流量均会受到邻近的前几个时刻的影响, 而且它也会影响之后几个时刻

的客流量, 体现了区域客流量的邻近性。

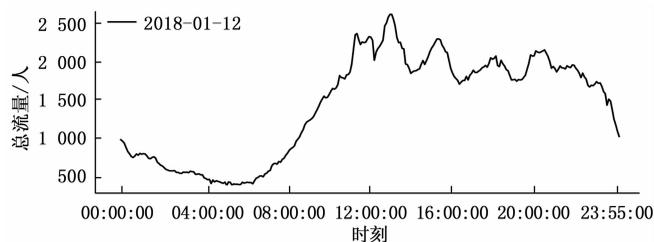


图 1 区域流量邻近性

1.2.2.2 相似性

图 2 将 12:00 区域的客流量依次与 11:00、10:00、9:00 区域客流量做差, 差值大于 10 的区域用白色表示, 其余区域用黑色表示。从图 2 中可以看到, 白色区域从整体上看属于少数, 说明大部分区域客流量相差不大, 体现了时间上的相似性。

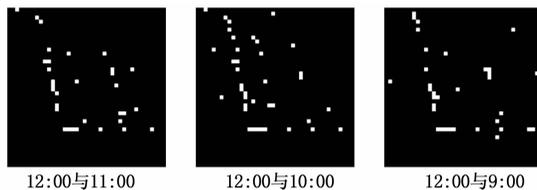


图 2 区域流量相似性

1.2.2.3 周期性

图 3 显示了连续五天的区域客流量, 从图 3 可以看到每天的客流量变化趋势是大体相同的, 每天同一时刻的客流量与 1 天前、2 天前的客流量存在相似性, 呈现出区域客流量的周期性。

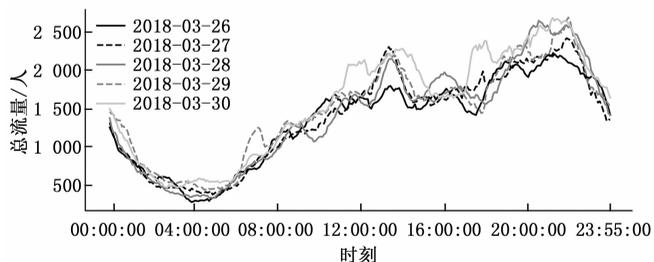


图 3 区域流量周期性

1.2.2.4 趋势性

图 4 显示了时长为 6 个月, 间隔为 1 周, 每早 8:00 的客流量, 随着气温变暖, 同一时刻客流量增多, 体现了区域客流量的趋势性。

1.2.3 季节性影响

在区域客流量相关的研究中经常会提到“季节性”这个概念, 它反映了由于天气因素、日历效应和时机决策的不同, 客流量在时间分布上的不均匀, 最终导致旅游市场具有明显的淡旺季。具体在区域客流量的研究上, 需要考虑的因素分为天气和法定节假日等。

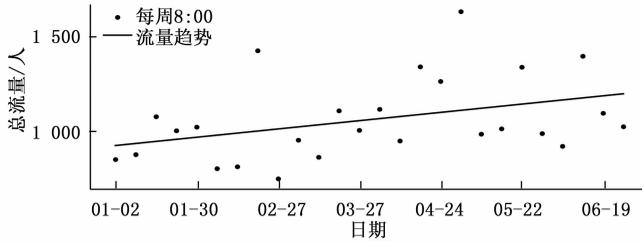


图 4 区域流量趋势性

1.3 Quad-ResNet 模型框架

基于时空残差网络的区域客流量预测方法 Quad-ResNet 模型的整体架构如图 5 所示, 模型主要分为 5 个部分, 通过 4 个残差网络分别来模拟时间的邻近性、相似性、周期性和趋势性, 一个两层全连接网络模拟季节性影响。残差网络由一个卷积层、 L 个残差单元和一个卷积层组成, 这种结构可以模拟空间邻近性和相似性。4 个残差网络的输出 $o_p^{[L+2]}$ 、 $o_q^{[L+2]}$ 、 $o_r^{[L+2]}$ 、 $o_s^{[L+2]}$ 通过参数矩阵融合为 o_f , o_f 与全连接网络的输出 o_e 进行融合。最后, 通过 Tanh 函数将融合后的输出映射到 $[-1, 1]$ 。

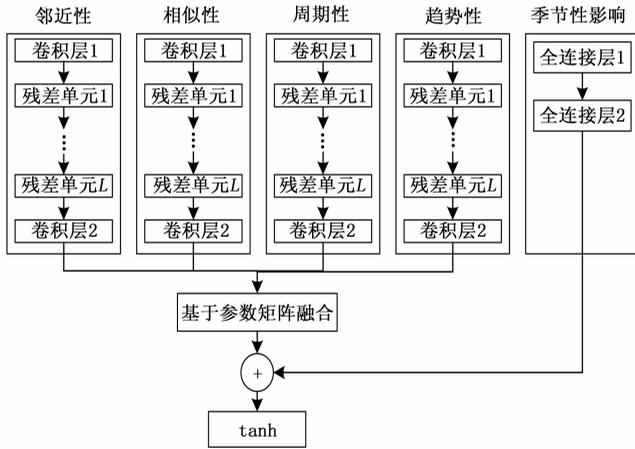


图 5 Quad-ResNet 模型整体架构

4 个残差网络结构是相同的, 以邻近性部分为例。应用 BN (Batch Normalization)^[24] 后残差单元的计算如式 (2)、式 (3) 所示:

$$a^{[t+1]} = w^{[t+1]} * g(a^{[t]}) \quad (2)$$

$$a^{[t+2]} = w^{[t+2]} * g(a^{[t+1]}) + a^{[t]} \quad (3)$$

式中, $*$ 表示卷积操作; g 表示激活函数 ReLU; $w^{[t+1]}$ 、 $w^{[t+2]}$ 是可学习参数。

邻近性部分的输入序列长度记为 l_p , 邻近性时间间隔为 $p=1$, 输入序列为 “ $x_{t-l_p}, x_{t-(l_p-1)}, \dots, x_{t-1}$ ”, 最后得到邻近性部分的输出记作 $o_p^{[L+2]}$ 。

相似性部分的输入序列长度记为 l_q , 相似性时间间隔为 $q=12$, 输入序列为 “ $x_{t-l_q}, x_{t-(l_q-1)}, \dots, x_{t-q}$ ”, 最后得到相似性部分的输出 $o_q^{[L+2]}$ 。

周期性部分的输入序列长度记为 l_r , 周期性时间间隔为

$r=288$, 输入序列为 “ $x_{t-l_r}, x_{t-(l_r-1)}, \dots, x_{t-r}$ ”, 最后得到周期性部分的输出 $o_r^{[L+2]}$ 。

趋势性部分的输入序列长度记为 l_s , 趋势性时间间隔为 $s=2016$, 输入序列为 “ $x_{t-l_s}, x_{t-(l_s-1)}, \dots, x_{t-s}$ ”, 最后得到趋势性部分的输出 $o_s^{[L+2]}$ 。

邻近性部分、相似性部分、周期性部分与趋势性部分通过参数矩阵进行融合, 融合后的输出 o_f 如式 (4) 所示:

$$o_f = \tau_w * o_p^{[L+2]} + \tau_q * o_q^{[L+2]} + \tau_r * o_r^{[L+2]} + \tau_s * o_s^{[L+2]} \quad (4)$$

式中, $*$ 表示 Hadamard 积; $\tau_w, \tau_q, \tau_r, \tau_s$ 是可学习的参数, 分别用来调整邻近性、相似性、周期性、趋势性的影响程度。

将 o_f 与外部影响部分输出 o_e 融合, 对融合后的输出应用 Tanh 激活函数得到 t 时刻的预测值 \hat{x}_t , 使得 \hat{x}_t 在 $[-1, 1]$ 的范围内。 \hat{x}_t 的计算如式 (5) 所示:

$$\hat{x}_t = \tanh(o_f + o_e) \quad (5)$$

模型采用 MSE (Mean Square Error, 均方误差) 来计算损失, 损失函数 $L(\theta)$ 如式 (6) 所示:

$$L(\theta) = \|x_t - \hat{x}_t\|_2^2 \quad (6)$$

式中, θ 是模型中所有可学习的参数; $\|w\|_2^2$ 是矩阵 $x_t - \hat{x}_t$ 的 L2 范数。

2 实验设计与分析

2.1 模型调优实验

2.1.1 实验数据集

原始流量数据来源腾讯位置大数据网站, 爬取陕西省宝鸡市扶风县法门镇 2018 年 1 月 1 日~2018 年 6 月 30 日的 APP 定位数据, 时间间隔为 5 分钟, 转换为区域客流量数据后, 共包含 52 128 个时刻。

采用扶风县的历史天气数据作为法门镇旅游景区的天气数据, 天气数据包含日期、天气状况、气温、风力风向这四个属性。节假日数据来源于开放 API, 工作日标识为 0, 周末休息日标识为 1, 法定节假日标识为 2。

2.1.2 超参数设置

Quad-ResNet 模型使用 Adam 优化算法进行训练, batch size 设置为 32, 学习率设置为 0.0001, 损失函数设置为 MSE。邻近性时间间隔的单位为 1 个时刻, 相似性时间间隔的单位为 1 个小时, 周期性时间间隔的单位为 1 天, 趋势性时间间隔的单位为 1 周。由于数据集的时间间隔是 5 分钟, 因此邻近性时间间隔 $p=1$, 相似性时间间隔 $q=12$, 周期性时间间隔 $r=288$, 趋势性时间间隔 $s=2016$ 。

2.1.3 模型评估标准

采用 RMSE (Root Mean Squared Error, 均方根误差) 对模型进行评价, RMSE 的计算如式 (7) 所示。RMSE 越小则说明模型的误差越小、精度越高。

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (x_i - \hat{x}_i)^2} \quad (7)$$

式中, \hat{x}_i 表示预测值; x_i 表示实际值; m 为所有预测数据的总数。

2.1.4 参数选择实验

参数选择实验主要是对邻近性序列长度、周期性序列长度、相似性序列长度、趋势性序列长度与残差单元数量进行选择。

以邻近性序列长度选择实验为例, 实验结果如图 6 (a) 所示。从图中可以看到, 随着 l_p 变大, RMSE 首先减小然后平稳最后增大。 $l_p = 0$ 时, 表示不使用邻近性部分, 导致 RMSE 很大, 说明邻近性部分有助于提高模型的精度。 $l_p = 2$ 时, RMSE 最小, 表明此时模型的精度最高。 $l_p = 6$ 时 RMSE 反而比之前更大, 说明较长的邻近性序列不但无法提升模型的精度反而可能导致模型的精度下降。因此, 最终选取邻近性序列长度 $l_p = 2$, 此时模型的误差最小, 精度最高。根据图 6 (b) ~ (e) 所示, 最终选取周期性序列长度 $l_r = 3$, 相似性序列长度 $l_q = 4$, 趋势性序列长度 $l_s = 1$, 残差单元数量为 4。

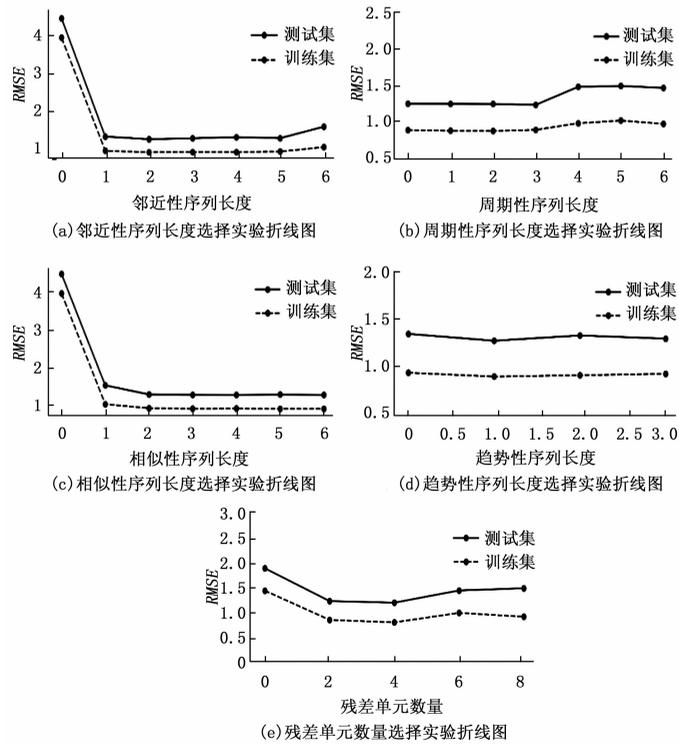


图 6 参数选择实验结果图

2.2 对比实验

2.2.1 实验设计

为了验证模型的有效性, 本文选取了 3 个模型 ST-ResNet, LSTM, CNN 与 Quad-ResNet 做性能比较, 其中深度学习模型 ST-ResNet, LSTM, CNN 设置的参数值与 Quad-ResNet 中的保持一致。

2.2.2 实验结果分析

各个模型的预测结果如表 1 示, 从表可以看出 Quad-

ResNet 模型的 RMSE 最小, 说明该模型的预测精度最高。LSTM-3、LSTM-6、LSTM-12 模型的 RMSE 只比 Quad-ResNet 模型的 RMSE 稍大一些, 说明 LSTM 模型能够有效地捕获短期的时间相关性, 并且得到较好的预测结果, 但是空间相关性对于预测结果也有着重要的影响, 不能只考虑时间相关性, 否则无法进一步地提升精度。

表 1 实验结果对比表

模型	RMS
ELSTM-3	1.452 281
LSTM-6	1.446 236
LSTM-12	1.479 850
LSTM-144	1.494 452
LSTM-288	1.535 349
LSTM-2016	1.953 422
CNN	1.923 737
ST-ResNet	1.379 933
Quad-ResNet	1.227 108

LSTM-3、LSTM-6、LSTM-12、LSTM-144、LSTM-288 模型的 RMSE 比较接近, 明显小于 LSTM-2016 模型, 同时, 随着 lookback 的增加, 模型的 RMSE 先减小后增大, 说明 LSTM 模型可能很难捕获非常长期的时间相关性 (例如, 一天、一周)。

CNN 模型的 RMSE 明显比 Quad-ResNet、LSTM-3、LSTM-6、LSTM-12、LSTM-144、LSTM-288 模型大, 仅仅略小于 LSTM-2016 模型, 说明浅层的 CNN 可能很难捕获到足够的空间相关性, 导致模型的预测精度不佳。

ST-ResNet 模型的 RMSE 大于 Quad-ResNet 模型, 这是由于 ST-ResNet 模型只考虑了时间的邻近性、周期性、趋势性, 没有考虑时间的相似性, 导致模型的精度无法进一步地提升, 说明短期的时间相关性对区域客流量预测精度的影响明显大于长期的时间相关性。邻近性、相似性属于短期的时间相关性, 周期性、趋势性属于长期的时间相关性。Quad-ResNet 模型考虑了时间的相似性, 因此实验结果好于 ST-ResNet 模型。

综合以上各个结论可以得出, 本文提出的针对区域客流量预测的 Quad-ResNet 模型的预测结果较好, 该模型对时间相关性和空间相关性的考虑比较周全, 具有一定的泛化能力, 同时该模型在训练和预测上的操作明显比 LSTM 模型更简单方便, 证明 Quad-ResNet 模型是一个优秀高效的模型, 适用于区域客流量的预测。

3 结束语

本文提出了一种基于时空残差网络的区域客流量预测方法, 即根据行人定位数据、天气和节假日数据预测每个地区的客流量, 从而找到旅游景区的客流量热点区域。本

文选取了 3 个模型与 Quad-ResNet 模型做性能比较, 证明 Quad-ResNet 模型更适合区域客流量的预测。但是还有一些方面需要完善, 本文的区域流量是通过行人数据得到的, 如果可以融合更多的交通流量, 比如自行车轨迹数据、出租车轨迹数据等其他数据, 在此基础上预测的结果应该更符合真实情况。本文考虑的影响因素也并不代表所有影响, 未考虑到突发事件或一些未知的原因, 如果可以挖掘出其他影响因素进行分析, 从而增强预测模型的实际意义, 进一步提高模型的精确性。

参考文献:

- [1] Lee J, Hong B, Lee K, et al. A prediction model of traffic congestion using weather data [A]. 2015 IEEE International Conference on Data Science and Data Intensive Systems (DSDIS) [C]. IEEE Computer Society, 2015.
- [2] Bianco V, Manca O, Nardini S. Electricity consumption forecasting in Italy using linear regression models [J]. Energy, 2009, 34 (9): 1413 - 1421.
- [3] Xu H F, et al. New grey prediction model and its application in forecasting land subsidence in coal mine [J]. Natural Hazards, 2014, 71 (2): 1181 - 1194.
- [4] Kan M L, Lee Y B, Chen W C. Apply grey prediction in the number of tourist [A]. Fourth International Conference on Genetic & Evolutionary Computing [C]. IEEE Computer Society, 2010.
- [5] Min X, et al. Urban traffic network modeling and short-term traffic flow forecasting based on GSTARIMA model [A]. 2010. 13th International IEEE Conference on Intelligent Transportation Systems (ITSC) [C]. 2010: 1535 - 1540.
- [6] Song G F, et al. Prediction for tourist attractions daily traffic based on modified genetic algorithm optimized BP neural network [J]. Journal of Chinese Computer Systems, 2014, 20 (6): 232 - 238.
- [7] Wei Y, Chen M C. Forecasting the short-term metro passenger flow with empirical mode decomposition and neural networks [J]. Transportation Research Part C Emerging Technologies, 2012, 21 (1): 148 - 162.
- [8] Xie M Q, Li X M, Zhou W L, et al. Forecasting the short-term passenger flow on high-speed railway with neural networks. [J]. Computational Intelligence & Neuroscience, 2014 (9): 23.
- [9] Feng Y U, et al. A short-term load forecasting model of natural gas based on optimized genetic algorithm and improved BP neural network [J]. Applied Energy, 2014, 134: 102 - 113.
- [10] Lü Y, Duan Y, Kang W, et al. Traffic Flow prediction with big data: a deep learning approach [J]. IEEE Transactions on Intelligent Transportation Systems, 2015, 16 (2): 865 - 873.
- [11] Fu R, Zhang Z, Li L. Using LSTM and G RU neural network methods for traffic flow prediction [A]. 2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC) [C]. IEEE, 2016.
- [12] Wu Y, Tan H, Qin L, 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] Song X, Kanasugi H, Shibasaki R. Deep Transport: prediction and simulation of human mobility and transportation mode at a citywide level [A]. International Joint Conference on Artificial Intelligence [C]. AAAI Press, 2016.
- [14] Guo J, Xie Z, Qin Y, et al. Short-Term Abnormal Passenger Flow Prediction Based on the Fusion of SVR and LSTM [J]. IEEE Access, 2019 (99): 1.
- [15] Wei X U, Huang H K, Qin Y. Study of railway passenger flow forecasting method Based on spatio-temporal Data Mining [J]. Journal of Northern Jiaotong University, 2004: 402 - 405.
- [16] Hribar R, et al. A comparison of models for forecasting the residential natural gas demand of an urban area [J]. Energy, 2018.
- [17] Li Y F, Cao H. Prediction for tourism flow based on LSTM neural network [J]. Procedia Computer Science, 2018.
- [18] Zhan X, Zheng Y, Yi X, et al. Citywide traffic volume estimation using trajectory data [J]. IEEE Transactions on Knowledge & Data Engineering, 2017, 29 (2): 272 - 285.
- [19] Ma X, Dai Z, He Z, et al. Learning traffic as images: A deep convolutional neural network for large-scale transportation network speed prediction [J]. Sensors, 2017, 17 (4).
- [20] Zhang J, Zheng Y, Qi D, et al. DNN-based prediction model for spatio-temporal data [A]. ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems [C]. ACM, 2016.
- [21] Zhang J, Zheng Y, Qi D. Deep Spatio-Temporal residual networks for citywide crowd flows prediction [J]. Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence (AAAI-17), 2017: 1655 - 1661.
- [22] 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.
- [23] 张可云, 王裕瑾, 王婧. 空间权重矩阵的设定方法研究 [J]. 区域经济评论, 2017 (1): 19 - 25.
- [24] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift [A]. International Conference on International Conference on Machine Learning [C]. JMLR.org, 2015.