

基于时空序列预测模型的地铁站客流量预测

袁世立, 徐浩楠, 沈路尧, 张卫丰

(南京邮电大学 计算机学院, 江苏 南京 210023)

摘要: 人流量预测在智能交通服务领域发挥着重要作用, 交通管理者能够通过提早预测人流量来制定针对性措施, 减少拥堵情况发生, 缓解交通压力。然而, 传统客流量预测通常仅利用历史数据与当前数据的关系进行时间序列预测, 精度无法保证。为有效提升预测精度, 提出一种时空序列预测模型来预测地铁客流量。该模型采用图卷积神经网络提取各线路之间的空间关系特征, 采用长短期记忆网络提取各线路本身的时间特征。利用南京地铁各线路1年来的客流量数据进行验证实验, 发现所提模型比传统的ARIMA时间序列预测模型、长短期记忆网络模型的预测准确性更高, 尤其在处理非平稳数据时预测误差降低了40%。

关键词: 人流量预测; 时空序列预测模型; 图卷积神经网络; 长短期记忆网络

DOI: 10.11907/rjdk.241550

中图分类号: TP183

文献标识码: A

文章编号: 1672-7800(2026)004-0083-06

扫描二维码阅读全文:



Prediction of Subway Station Passenger Flow Based on Spatial and Temporal Series Prediction Model

YUAN Shili, XU Haonan, SHEN Luyao, ZHANG Weifeng

(School of Computer Science, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: The prediction of pedestrian flow plays an important role in the field of intelligent transportation services. Traffic managers can develop targeted measures by predicting pedestrian flow in advance, reducing congestion and alleviating traffic pressure. However, traditional passenger flow prediction usually only relies on the relationship between historical data and current data for time series prediction, and the accuracy cannot be guaranteed. To effectively improve prediction accuracy, a spatiotemporal sequence prediction model is proposed to predict subway passenger flow. This model uses graph convolutional neural networks to extract spatial relationship features between each line, and uses long short-term memory networks to extract temporal features of each line itself. Using the passenger flow of various lines of Nanjing Metro over the past year for verification experiments, it was found that the proposed model has higher prediction accuracy than traditional ARIMA time series prediction models and long short-term memory network models, especially when dealing with non-stationary data, with a 40% reduction in prediction error.

Key Words: prediction of pedestrian flow; spatio-temporal prediction model; graph neural network; long and short term memory network

0 引言

在城市化进程加速的当下, 地铁凭借其高效、便捷等特性, 已然成为民众出行的主要方式之一。然而, 地铁日益增长的巨大客流量犹如一把双刃剑, 在彰显其强大运输能力的同时, 也给运营安全与管理带来了严峻挑战和潜在

危险。2015年上海新年庆祝活动因人群过度拥挤, 最终导致49人受伤、36人死亡的严重悲剧^[1]。科学合理开展地铁站人流管理、精准进行车次分配、有效实施拥堵缓解策略以及妥善安排工作人员, 对于预防拥挤事故的发生、营造安全舒适的出行环境具有至关重要的现实意义。若交通管理者能够借助先进技术手段, 准确预测地区人流量, 便可依据预测结果制定出具有高度针对性的交通管理

收稿日期: 2025-03-18

基金项目: 国家自然科学基金面上项目(62272214); 南京市国际合作项目(202201010)

作者简介: 袁世立(1999-), 男, 南京邮电大学计算机学院硕士研究生, 研究方向为深度学习、生物信息学; 徐浩楠(2000-), 男, 南京邮电大学计算机学院硕士研究生, 研究方向为分布计算; 沈路尧(2004-), 男, 南京邮电大学计算机学院学生, 研究方向为代码仓库; 张卫丰(1974-), 男, 博士, CCF高级会员, 南京邮电大学计算机学院教授, 研究方向为代码管理、持续集成。本文通讯作者: 张卫丰。

措施。例如,依据不同时段、不同站点的人流量预测数据灵活调整车次安排,优化人员岗位配置,提前做好安全布控与应急准备工作。同时,通过及时发布人流预警信息,引导乘客合理规划出行路线,有效避免人流过度集中,从而减少突发事件的发生概率^[2-3]。综上所述,精准预测地铁人流量不仅是实现科学人流分流、提升交通管理水平的关键所在,更是缓解城市交通压力、推动城市经济健康可持续发展的支撑。

最初研究者多将人流量预测视为单纯的时间序列预测问题,将时空序列数据拆分为时间序列后再建模预测。20世纪70年代提出的整合移动平均自回归模型(Autoregressive Integrated Moving Average, ARIMA)旨在解决时间序列数据的随机性、平稳性和季节性分析问题,其核心思想为通过数学建模解释时间序列中的自相关结构,被广泛用于人流量预测,但在处理大规模数据时效率较低^[4]。基于线性回归的预测方法不断发展,产生了季节性ARIMA(SARIMA)和ARIMA加解释变量(ARIMAX)等分支^[5]。这些模型在短期预测中效果良好,但在长期预测任务中表现欠佳。在时空序列分析中,根据对象的不同常采用不同的方法,有的侧重于时间信息,有的侧重于空间密度,但通常未能综合考虑时间和空间的影响^[6]。空间—时间自回归移动平均模型(Spatio-Temporal Autoregressive Moving Average Model, STARMA)模型结合了时间和空间两个维度,对平稳时空序列的处理效果较好,在时空序列预测中大放异彩^[7]。然而,在真实环境下,时空序列往往并非平稳,且大部分为非线性数据,STARMA模型对非线性数据的感知能力不强,预测准确度较低^[8]。

随后,机器学习方法开始应用于人流量预测。例如, Sun等^[9]基于时间节点间的相互影响构建贝叶斯网络来进行交通流量预测;Chen等^[10]通过建立马尔可夫随机场来寻找可能因人流量过大而拥堵的地点,为交通指挥提供依据。Das等^[11]利用模糊贝叶斯网络解决人流量预测问题。然而,以上方法将时空序列问题视为单纯的时间或空间序列问题,无法捕捉时间与空间数据之间的联系,过度依赖经验特征提取,模型可移植性低。

近年来,深度学习技术在海量数据的推动下迅速发展。基于深度学习的方法能有效挖掘时空序列数据中的线性和非线性特征。例如,王佳璆等^[12]建立了基于深度学习的时空序列预测模型,利用先验概率数据提高了学习精度。Shi等^[13]提出基于卷积的长短期记忆模型ConvLSTM,专门用于处理时空序列数据,其将前馈计算替换为卷积,避免了数据冗余。Zhang等^[14]提出基于深度学习的时空数据预测模型DeepST用于实时人流预测等任务,其将时间序列数据划分为时间近邻、周期性、季节性3个子序列进行融合计算。在此基础上,Zhang等^[15]提出ST-ResNet模型,在3个子序列中设置残差块,融合全连接层提取外部因素,用于预测城市中每个区域的流入和流出客流量。

机器学习、深度学习等技术使时间序列预测不再依赖完美的数据模型,而是基于大量数据进行训练与学习,如使用递归神经网络(Recursive Neural Network, RNN)^[16]、长短期记忆网络(Long Short-Term Memory, LSTM)^[17]等从以往的数据中学习。

基于深度学习的时间序列预测方法虽然取得了较大进展,但仍有改进空间:①以往研究虽然结合了时间和空间信息,但未能综合考虑二者的影响,大多只考虑最邻近的影响因素;②现有时空预测模型在面对非平稳的时间序列数据时感知力不强,准确度较差。为此,本文提出一种基于图卷积神经网络(Graph Convolution Networks, GCN)与LSTM的时空预测算法GCN-LSTM。其中,GCN用于提取各线路间的空间关系特征,LSTM用于提取各线路的时间特征,二者融合后进行人流量预测。在南京地铁客流量数据集上的测试结果显示,GCN-LSTM算法在平稳和非平稳数据上的表现均优于ARIMA和LSTM模型。

1 理论基础

1.1 平稳时间序列建模

ARIMA中的AR表示自回归方法,I表示差分方法,MA表示滑动平均方法。首先,AR模型用于描述当前值与历史值之间的关系,是一种根据自身历史数据预测未来数据的方法,当随机扰动为一个白噪声时, p 阶的自回归模型表示为:

$$X_t = \alpha_1 X_{t-1} + \alpha_2 X_{t-2} + \cdots + \alpha_p X_{t-p} + \varepsilon_t \quad (1)$$

式中: p 表示根据 p 个时期的历史数据来预测当前指定时刻的值; α 表示自相关系数; ε_t 表示 t 时间点的误差项; X_t 表示时间序列数据。

其次,MA模型在AR模型的基础上进行参数估计,当时间序列成为白噪声序列的线性组合,并且其当前状态与任何历史状态不再有关时,能够得到MA(q)模型。表示为:

$$X_t = \varepsilon_t + \beta_1 \varepsilon_{t-1} + \cdots + \beta_q \varepsilon_{t-q} \quad (2)$$

式中: β 表示自相关系数。

最后,将AR(p)模型与MA(q)模型相结合,能够得到ARMA(p, q)模型。表示为:

$$X_t = \alpha_1 X_{t-1} + \alpha_2 X_{t-2} + \cdots + \alpha_p X_{t-p} + \varepsilon_t + \beta_1 \varepsilon_{t-1} + \cdots + \beta_q \varepsilon_{t-q} \quad (3)$$

式中: p 和 q 表示滞后值。

ARMA模型并不能有效处理非平稳数据,需要将数据转化为平稳的时间序列。差分方法可简单地挖掘一个时间序列的平稳序列。在模型选择时,首先对时间序列数据进行差分,然后通过AR模型和MA模型组成ARMA模型,最后形成ARIMA模型。ARIMA(p, d, q)建模一般分为以下4个步骤:①通过已知数据绘图或ADF(Augmented Dickey-Fuller)检验判断时间序列是否平稳,若序列不平

稳,则进行 d 阶差分,转化为平稳序列,其中参数 d 为对时间序列数据进行差分的阶数;②求得平稳序列的自相关系数和偏自相关系数,并通过自相关图拖尾阶数和偏自相关图拖尾阶数确定 q 和 p 的值,进而确定 $MA(q)$ 和 $AR(p)$ 模型。如果偏自相关图和自相关图均呈现截尾的性质,则不适合使用ARIMA模型进行预测;③对模型进行参数估计和假设检验,不通过则判定模型不可靠;④通过模型进行预测分析,计算误差等评估指标。

1.2 LSTM网络

LSTM是一种改进后的循环神经网络(Recurrent Neural Network, RNN),主要解决了RNN网络无法处理长距离依赖的问题^[18]。原始RNN的隐藏层中原本只有一个状态 h ,LSTM网络则增加了一个保存长期状态的单元 c (cell state),使新的模型具有了记忆能力,能够记住长期状态。

LSTM模型凭借其独特的设计机制,即运用遗忘门、输入门和输出门这3个关键门控结构,成功实现了对信息的选择性记忆与遗忘功能,具有高效的长短期信息整合、训练以及精准的预测功能^[19]。以下分别对3个门进行介绍。

遗忘门通常使用激活型函数来决定需要从LSTM内存中删除哪些信息,这个决定本质上是基于 h_{t-1} 和 x_t 的值。该门的输出为 f_t ,值在0~1之间,其中0表示完全去掉了学习到的值,1表示保留了整个值。输出的计算方式为:

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

输入门由以下两层组成:①sigmoid层。经过sigmoid层时计算得到需要更新的值,将该值送入LSTM存储的单元中。②tanh层。经过tanh层时,LSTM会自动创建一个新向量存储候选值,同时该向量也会被添加到LSTM内存中。这两层输出值的计算方法分别为:

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

$$c_t = \tanh(W_{ch}[h_{t-1}], W_{cx}[x_t], b_c) \quad (6)$$

式中: i_t 返回的值决定了是否需要更新该值; c 为将要加入到LSTM下一层中的候选值向量。遗忘门与输入门的组合为LSTM内存提供了更新功能。表示为:

$$c_t = f_t \cdot c_{t-1} + i_t \cdot c_t \quad (7)$$

输出门首先使用Sigmoid激活函数层来决定LSTM内存的哪一部分对输出有贡献;其次执行一个非线性的tanh函数来映射为-1~1之间的值;最后将结果乘以一个激活层的输出,表示为:

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

$$h_t = o_t \cdot \tanh(c_t) \quad (9)$$

式中: o_t 为输出值; h_t 为-1~1之间的值。

2 GCN-LSTM网络

地铁线路可以被抽象成一个图模型,各线路作为顶点,中转站作为两条线路相邻的依据,将各线路的人流量数据作为每个顶点的特征向量。在整个图网络中,所有地

铁站之间都相互联系,一条地铁线路的人流量变化必然也会引起另一条地铁线路的人流量变化。基于以上思路,本文提出融合空间位置结构信息与时间序列数据的预测算法,通过时间序列建立描述数据时间特性的模型,根据图关系建立描述空间结构特征与相互作用的图模型。该算法融合了多层感知机、GCN和LSTM,包括输入层、图卷积层、时间序列预测层、数据融合层和训练层。其中,输入层输入时间序列的样本及标签数据、空间特征数据矩阵和空间关系矩阵。样本表示为:

$$Data_t = \{x_{t-1}, x_{t-1+1}, x_{t-1+2}, \dots, x_{t-1}\} \quad (10)$$

式中: x_t 表示第 t 天某线路的人流量; t 表示样本的时间片段长度,标签为 $Label_t = x_t$ 。

图卷积层对空间特征数据矩阵和空间关系矩阵进行卷积操作。该层包括两层GCN网络,用于提取各线路之间的关系特征,提高每个神经元的感受野,使每一层的空间信息能够更好地传递与提取。图卷积层可表示为一个非线性函数:

$$H^{l+1} = f(H^l, A) \quad (11)$$

式中: $H^0 = X$, $X \in R^{N \times D}$ 表示第一层的输入, N 和 D 分别表示图的节点个数和每个节点的维度,通过不同的函数 f 实现不同的模型。一般选用拉普拉斯矩阵作为实现的参数,表示为:

$$H^{l+1} = \sigma(LH^lW^l) \quad (12)$$

式中:拉普拉斯矩阵 $L = D - A$ 为一种度矩阵,能使图卷积层考虑自身节点信息自传递的问题。

时间序列预测层主要由LSTM层组成,时间数据在这一层中被提取出时间特征,随后将特征送入全连接层。数据融合层将LSTM神经元输出的结果与图卷积层输出的结果进行融合拼接,送入训练层中进行训练。

3 实验方法与结果分析

3.1 实验方法

本文实验数据通过爬虫技术从新浪微博南京官方每日各线路客流量获得,时间范围为2021年5月29日—2022年3月31日,共计10条线路的307条微博内容。对每条微博进行特征转换与提取,建立db数据库,最终得到3377条数据。除ARIMA模型可以使用一维单纯的时间序列数据进行训练,其余模型均需要分为输入集和输出集。本文通过设置滑窗的方式创建训练集,由于地铁客流量数据具有周期性,一般是随着工作日和双休日的变化而变化,因此设置时间段为14,即 $n=14$,以此进行时间片的切割。每个输入集样本大小为 10×14 ,输出集大小为 10×1 。

针对ARIMA模型,对数据进行差分处理、白噪声检测和ACF检验,判定数据为平稳、非白噪声的时间序列,计算自相关系数和偏自相关系数,分别呈现出14阶拖尾和1阶

拖尾的性质,因此选择 ARIMA(14, 0, 1) 模型。针对 LSTM 模型和 GCN-LSTM 模型,使用滑窗法将一段时间的人流量作为数据集,后一天的人流量作为标签集进行数据创建,其中 LSTM 模型分别进行滑步窗口的单步预测、滚动预测(即将每次的预测结果再当作训练集进行训练)以及长期多步预测。设置模型学习精度为 0.001,将均方根误差(Root Mean Square Error, RMSE)设置为训练损失,进行 700 轮、每轮 7 次的训练。

RMSE 用于测量实际值与预测值之间的差异,而直接使用实际值和预测值会出现跨度不统一的情况。因此,需要将数据提前归一化。采用模型预测接下来 m 天的人流量数据 $h(m)$,再结合实际中 m 天内真实的人流量数据 y 计算 RMSE。公式为:

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (h(i) - y)^2} \quad (13)$$

3.2 实验结果

3.2.1 正常时期预测效果比较

首先对数据进行拟合,针对数据没有异常的时期进行 29 天的预测。ARIMA 模型的预测结果如图 1 所示, RMSE 为 15.328, 误差较高。分析其原因可以发现,在正常数据前的一段时间内,数据趋势曾出现一次异常并迅速衰减,可能导致预测结果呈下降趋势。





Fig. 1 The prediction performance of ARIMA model under normal data

图1 正常数据下 ARIMA 模型的预测效果


LSTM 模型的预测结果如图 2 所示。从预测结果来看,长期预测的效果比短期预测和滑动窗口的滚动预测更好。具体表现为趋势变化的滞后或超前现象不如后两者明显,在低峰值处与原始数据的数值更为接近。这是由于训练数据具有周期性,进行长期多步预测时会有周期性因素的叠加,误差会较小,但对于无周期性或周期性较弱的的数据序列准确度会降低。相较于 ARIMA 模型, LSTM 模型的预测效果更好,但部分区间仍存在较大数值差异。

GCN-LSTM 模型的预测结果如图 3 所示。相较于 ARIMA 模型和 LSTM 模型, GCN-LSTM 模型的拟合程度更高, RMSE 分别降低了 3.73 和 7.82。




(a) Short term prediction

(a) 短期预测



(b) Rolling prediction of sliding windows

(b) 滑动窗口的滚动预测



(c) Long term prediction

(c) 长期预测

Fig. 2 Performance of LSTM model under normal data

图2 正常数据下 LSTM 模型的预测效果

3.2.2 异常时期预测效果比较

当预测期的数据出现异常时,本文对异常发生后 29 天的数据进行了预测。如图 4 所示, ARIMA 模型在异常数据出现后的预测效果很差,且在很长一段时间内难以恢复。相比之下,如图 5 所示, LSTM 模型对异常数据的预测




Fig. 3 The prediction performance of GCN-LSTM model under normal data

图3 正常数据下GCN-LSTM模型的预测效果

能力有所提升,这种提升仅体现在趋势变化上,但数值仍存在较大差距,基本呈现欠拟合状态。究其原因,LSTM模型和ARIMA模型均过度依赖过去一段时间的数据。当异常数据持续超过一定时间,后续数据将持续呈现异常状态,难以改变。




Fig. 4 The prediction performance of ARIMA model under abnormal data

图4 异常数据下ARIMA模型的预测效果

GCN-LSTM模型的预测效果如图6所示。可以看出,GCN-LSTM模型的预测效果比ARIMA和LSTM模型更好,基本趋势已能预测出来,且数值上的差距较小,受历史异常数据的影响亦比后两种模型小。时空序列处理方法虽然降低了历史数据对时间序列的影响,但增强了空间上的影响。一些地铁线路间歇性运营和停运,导致关系矩阵无法协调一致,产生矩阵特征的空值,进而使正常数据部分的拟合较差。

综上所述,ARIMA模型在一定周期内能够准确预测人流量变化的大体趋势,但其过于依赖长期历史数据,预测结果虽然趋势准确,但具体数值偏差较大,尤其在长期预测中劣势更为明显。LSTM模型能较好地把握各时间点间的相互影响,关注近期变化对当前人流量的影响,这一点




Fig. 5 Short term prediction performance of LSTM model under abnormal data

图5 异常数据下LSTM模型的短期预测效果




Fig. 6 The prediction performance of GCN-LSTM model under abnormal data

图6 异常数据下GCN-LSTM模型的预测效果

比ARIMA模型更优。其中,滑窗预测对于周期性数据和突发情况较少的数据预测效果良好,多步预测和单步预测在长期和短期预测上均能取得不错效果,但对其他线路的影响感知能力不强。GCN-LSTM模型通过图卷积层增强了各线路之间的影响关系,弥补了LSTM模型的缺点。当数据规律无异常时,相较前两者略有优势;而当数据多次异常、事故频发时,无论是长期预测还是短期预测,GCN-LSTM模型均较前两者具有明显优势。

4 结语

本文提出一种基于时空序列的预测模型GCN-LSTM用于地铁客流量预测。该模型依靠GCN提取各线路之间的空间关系特征,利用LSTM提取各线路的时间特征,实现了对平稳和非平稳时间序列数据的预测。在南京地铁每日各线路客流量数据集上进行测试发现:对于正常时间序列数据的预测,与ARIMA和LSTM相比,GCN-LSTM模型的RMSE分别降低了24.3%和40.3%;对于异常数据的预

测, RMSE 分别降低了 36.1% 和 28.8%。未来将结合天气、通行政策、地面交通等因素, 实现对地铁站日人流量变化趋势的精准预测。

参考文献:

- [1] ZHENG Y C. Full graphic records and subsequent reports of the serious new year stampede on the bund in Shanghai [N]. Exclusive Net, 2015-01-01.
郑渝川. 上海外滩新年严重踩踏事件图文全记录及后续报道 [N]. 独家网, 2015-01-01.
- [2] XIONG Y Y. Urban traffic-flow prediction based on deep learning [D]. Beijing: Beijing University of Posts and Telecommunications, 2020.
熊奕洋. 基于深度学习的城市人流量预测 [D]. 北京: 北京邮电大学, 2020.
- [3] CALABRESE F, FERRARI L, BLONDEL D V. Urban sensing using mobile phone network data: a survey of research [J]. ACM Computing Surveys (CSUR), 2014, 47(2): 1-20.
- [4] VOORT D V M, DOUGHERTY M, WATSON S. Combining Kohonen maps with ARIMA time series models to forecast traffic flow [J]. Transportation Research: Part C, 1996, 4(5): 307-318.
- [5] JIAO L, LI W J, ZHAO C M, et al. A season time series (SARIMA) prediction model based on Eviews [J]. Henan Journal of Preventive Medicine, 2015, 26(5): 349-352.
焦亮, 李文杰, 赵超敏, 等. 基于 Eviews 的季节时间序列 (SARIMA) 预测模型 [J]. 河南预防医学杂志, 2015, 26(5): 349-352.
- [6] WANG C C. Short time series based on machine learning [D]. Changsha: Hunan University, 2019.
汪成成. 基于机器学习的短时时间序列时空预测方法及应用研究 [D]. 长沙: 湖南大学, 2019.
- [7] CHANG G, ZHANG Y, YAO D Y. Prediction model for short-time traffic flow of regional road network based on spatial otemporal dependence [J]. Journal of Tsinghua University (Natural Science Edition), 2013, 53(2): 215-221.
常刚, 张毅, 姚丹亚. 基于时空依赖性的区域路网短时交通流预测模型 [J]. 清华大学学报 (自然科学版), 2013, 53(2): 215-221.
- [8] WANG S B, WANG J D, CHEN H Y. STARMA spatiotemporal sequence prediction model of the network [J]. Computer Application Research, 2014, 31(8): 2315-2319.
王尚北, 王建东, 陈海燕. STARMA 网络时空序列预测模型研究 [J]. 计算机应用研究, 2014, 31(8): 2315-2319.
- [9] SUN S, ZHANG C, YU G. A Bayesian network approach to traffic flow forecasting [J]. IEEE Transactions on Intelligent Transportation Systems, 2006, 7(1): 124-132.
- [10] CHEN P T, CHEN F, QIAN Z. Road traffic congestion monitoring in social media with hinge-loss Markov random fields [C]// 2014 IEEE International Conference on Data Mining, 2014: 80-89.
- [11] DAS M, GHOSH S K. FB-STEP: a fuzzy Bayesian network based data-driven framework for spatio-temporal prediction of climatological time series data [J]. Expert Systems with Applications, 2019, 117: 211-227.
- [12] WANG J Q, DENG M, CHENG T. Spatio-temporal sequence data analysis and modeling [M]. Beijing: Science Press, 2012.
王佳璆, 邓敏, 程涛. 时空序列数据分析和建模 [M]. 北京: 科学出版社, 2012.
- [13] SHI X J, CHEN Z R, WANG H, et al. Convolutional LSTM network: a machine learning approach for precipitation nowcasting [C]// Proceedings of the 28th International Conference on Neural Information Processing Systems, 2015: 802-810.
- [14] ZHANG J B, ZHENG Y, QI D K, et al. DNN-based prediction model for spatio-temporal data [C]// Proceedings of the 24th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems, 2016: 92.
- [15] ZHANG J B, ZHENG Y, QI D K. Deep spatio-temporal residual networks for citywide crowd flows prediction [DB/OL]. <https://arxiv.org/abs/1610.00081>.
- [16] SHI P Y. Research on prediction methods and their application based on recurrent neural network [D]. Ji'nan: Shandong Normal University, 2020.
时培莹. 基于循环神经网络的预测方法及其应用研究 [D]. 济南: 山东师范大学, 2020.
- [17] LIU H F, WANG Y R. Research on the short-term power load prediction algorithm based on LSTM [J]. Modern Information Technology, 2021, 5(23): 40-42.
刘海峰, 王艳如. 基于 LSTM 的短期电力负荷预测算法研究 [J]. 现代信息科技, 2021, 5(23): 40-42.
- [18] XIE X L. Research and application of cardiopulmonary sound separation method based on non-negative matrix factorization and neural network [D]. Guangzhou: Guangdong University of Technology, 2018.
谢型浪. 基于非负矩阵分解和神经网络的心肺音分离方法研究与应用 [D]. 广州: 广东工业大学, 2018.
- [19] FANG J. Neural network prediction and numerical simulation analysis of subway thermal environment state [D]. Beijing: Beijing Jiaotong University, 2020.
方杰. 地铁热环境状态的神经网络预测与数值模拟分析 [D]. 北京: 北京交通大学, 2020.

(责任编辑: 尹晨茹)