

城市轨道交通进出站短时客流预测模型研究

蔡昌俊

(广州地铁集团有限公司, 510335, 广州/正高级工程师)

摘要 针对城市轨道交通短时进出站客流的强随机性、周期性及非线性的特征,提出了一种基于小波变换与 Adam 算法优化的长短期记忆网络(LSTM)短时客流组合预测模型(即 WT-LSTM 组合模型),同时基于非饱和激活函数 ReLU 函数实现了 LSTM 的学习与训练。采用 LSTM 模型与 WT-LSTM 组合模型对广州地铁广州塔站的客流量进行预测,并对预测结果的误差进行对比分析。结果表明,WT-LSTM 组合模型能够较好地预测短时客流,预测结果优于单一 LSTM 模型。

关键词 城市轨道交通;短时客流量预测;组合模型;小波变换;长短期记忆网络

中图分类号 U293.13

DOI:10.16037/j.1007-869x.2021.09.004

Study on Urban Rail Transit Entry and Exit Short-term Passenger Flow Prediction Model

CAI Changjun

Abstract In view of short-term passenger flow in urban rail transit having characteristics of strong randomness, periodicity and non-linearity, a combined forecasting model (WT-LSTM combined model) of short-term passenger flow based on wavelet transform and LSTM (long short-term memory network) optimized by Adam algorithm is proposed. Meanwhile, the LSTM model is learned and trained by the unsaturated activation function ReLU function. Passenger flow at Guangzhou Metro Canton Tower station is predicted using LSTM single model and WT-LSTM combined model, and the error of the prediction results is compared and analyzed. Result shows that the WT-LSTM model can predict short-term passenger flow well, and the prediction effect of it is better than that of LSTM single model.

Key words urban rail transit; short-term passenger flow prediction; combined prediction model; wavelet transform; LSTM (long short-term memory network)

Author's address Guangzhou Metro Group Co., Ltd., 510335, Guangzhou, China

0 引言

在城市轨道交通网络化运营时期,客流过饱和情况时有发生,这对车站运营组织工作提出了很高的要求。准确预测车站短时客流量,并据此制定科学的客运计划和组织方案,将有助于实现车站客流的动态管理,提高车站的运营效率。

目前,针对短期交通量预测的模型主要包括:数理统计模型,如时间序列模型^[1]、卡尔曼滤波模型^[2]等;人工智能模型,如支持向量机(SVM)^[3]、长短期记忆网络(LSTM)、径向基函数(RBF)神经网络等;混合模型,如小波变换(WT)与自回归滑动平均模型(ARMA)的组合模型^[8]、完全总体经验模态分解与 LSTM 的组合模型^[9]、灰狼优化算法(GWO)与小波神经网络(WNN)的组合模型^[10]、卷积神经网络(CNN)与 LSTM 的组合模型、WT 与 SVM 的组合模型^[14]等。以上研究成果对城市轨道交通客流预测具有重要的意义。但短时客流存在随机性、突变性、动态性等难以被精确预测的特点,对于短时客流预测,现有模型存在预测精度不够高或泛化能力不强等问题。数理统计模型对数据的随机变化不够敏感,针对随机性较强的短时客流,其预测性能比较有限^[11];人工智能模型能够描述城市轨道交通短时客流量数据的非线性特征,但对于海量的小粒度短时客流数据,其预测精度还有待进一步提高。混合模型综合了各种单一预测模型的优势,在一定程度上能够提高预测精度。但是,组合模型的组合方式及组合内容对预测精度的影响较大,因此需根据数据特点选择合适的组合模型。

循环神经网络(RNN)是一种强大的深度学习方法,可以将数据传递到先前的或同一层的神经元。LSTM 是一种特殊的 RNN,在各种各样现实问题上的表现都非常好^[16]。Adam 算法结合了 Momentum 和 RMSProp 两种算法的优点,可通过计算梯度的一阶矩估计和二阶矩估计,为不同参数设置

自适应学习率,其学习率的取值接近 Momentum 算法,其收敛速率显著高于固定学习率的算法^[17]。小波变换是一种数据预处理方法,在时域和频域都有着良好的局部分辨能力,在处理非线性和非稳定性数据方面具有很大的应用价值^[18],可以弥补传统 LSTM 模型没有考虑数据波动性的缺陷。因此,本文提出了一种基于小波变换和 LSTM (即 WT-LSTM)的组合模型,并利用 Adam 算法作为 LSTM 的训练算法,使用非饱和激活函数 ReLU 函数替代饱和函数激活函数 Tanh 函数。

1 组合预测模型构建

1.1 小波变换

城市轨道交通进出站客流量是随时间变化的信息,原始数据几乎都会受复杂因素的影响而携带一定的噪声,因此,需要采取一些方法提取、消除噪声。小波变换是目前应用最广泛的去噪方法,可克服傅里叶变换无法有效分辨时域信息的缺陷。小波变换分为连续型变换和离散型变换。本文采用离散型变换,其表达式为:

$$\psi_{j,k} = a_0^{-m/2} \int y(t) \psi^*(a_0^{-m}t - nb_0) dt \quad (1)$$

式中:

$\psi_{j,k}$ ——离散型小波变换;

t ——时刻;

a_0 ——尺度参数;

b_0 ——平移参数;

$y(t)$ 为基本信号函数;

$\Psi(t)$ ——母小波;

Ψ^* ——复共轭函数;

m ——缩放常数;


n ——平移常数。

常用的小波基函数包括 Symlets、Daubechies、Haar 等。

1.2 LSTM

LSTM 可使用新的单元格解决通用 RNN 的长期依赖问题,从而确定信息的实用性。如图 1 所示,一个逻辑单元包含忘记门 (Forget Gate)、输入门 (Input Gate) 和输出门 (Output Gate)。

非饱和激活函数 ReLU 函数相对饱和激活函数 (如 Sigmoid 和 Tanh 函数),能解决“梯度消失”的问题,收敛速度更快。因此,本文利用 ReLU 函数来替代 Tanh 函数。LSTM 的工作过程如下:



注: i_t ——输入门; o_t ——输出门; x_t ——计算模型输入值; c_t ——单元状态值; h_t ——计算模型输出值; f_t ——忘记门。

图 1 LSTM 结构图^[19]

步骤 1: 忘记门 f_t 控制和选择逻辑单元所需要的信息,其由输入值 x_t 和 $t-1$ 时刻的隐藏层输出 h_{t-1} 决定。表达式如下:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (2)$$

式中:

σ ——Sigmoid 激活函数;

W_f ——权重矩阵;

b_f ——偏置项。

步骤 2: 输入门 i_t 通过 Sigmoid 函数来更新参数。 x_t 和 h_{t-1} 结合 ReLU 函数产生一个新的候选状态值 \tilde{c}_t 。 c_t 是由 \tilde{c}_t 和 i_t 共同创建的新的单元状态值,相关表达式为:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (3)$$

$$\tilde{c}_t = \text{ReLU}(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t \quad (5)$$

式中:

W_i ——权重矩阵;

b_i, b_c ——偏置项;

W_c ——权重矩阵。

步骤 3: 隐藏层单元输出值 h_t 由输出门 o_t 和单元状态值 c_t 计算获得,表达式为:

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (6)$$

$$h_t = o_t * \text{ReLU}(c_t) \quad (7)$$

式中:

W_o ——权重矩阵;

b_o ——偏置项。

步骤 4: 根据 h_t , 进而可构造计算模型的均方误差。通过 Adam 算法最小化目标函数、Adam 算法优化 LSTM 模型的过程见文献^[20]。

1.3 WT-LSTM 模型

WT-LSTM 组合模型预测流程如图 2 所示。

WT-LSTM 组合模型实现步骤如下:

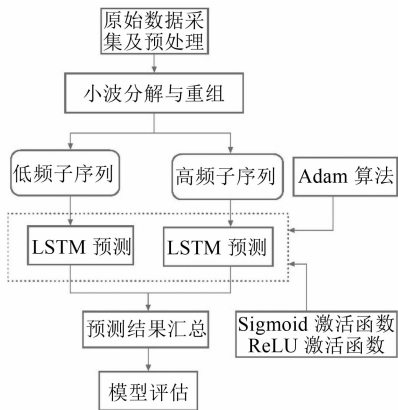


图2 WT-LSTM 组合模型预测流程图

步骤1:从车站的AFC(自动售检票)设备终端获取历史客流数据,预处理后作为WT-LSTM模型的输入参数。本文数据预处理主要包括归一化处理,使原始值归一化为区间 $[0,1]$ 中的值^[21]:

$$x' = \frac{x_i - x_{mid}}{x_{max} - x_{mid}} \quad (8)$$

$$x_{mid} = (x_{min} + x_{max})/2 \quad (9)$$

式中:

x_i ——原始数据;

x_{min}, x_{max} ——分别为原始数据的最小值和最大值。

步骤2:确定小波函数 $\Psi(t)$ 和分解层数 N 。对原始信号采用Mallat算法作 N 层分解,得高频子序列 D_1, D_2, \dots, D_N 和低频子序列 A_N ;再利用Mallat算法重构公式,得重构高频子序列 d_1, d_2, \dots, d_N 和低频子序列 a_N 。重构后的序列与原始序列长度相同。小波分解和重构公式如式(10)和式(11)所示。

$$D_i = GA_{i-1}; A_i = HA_{i-1}, \quad i = 1, \dots, N \quad (10)$$

式中:

H, G ——分别为低通滤波器和高通滤波器;

i ——分解层数;

A_0 ——原始客流数据(当 $i=1$ 时)。

$$a_{i-1} = H^* A_i + G^* D_i, \quad i = N, N-1, \dots, 1 \quad (11)$$

式中:

H^*, G^* ——分别为低通滤波器和高通滤波器的对偶算子。

步骤3:将高频子序列 d_1, d_2, \dots, d_N 和低频子序列 a_N ,分别代入到LSTM模型中进行分析及预测。通过变量控制方法确定LSTM模型的隐藏单元数量和迭代次数,并将Adam算法用于LSTM的短时客流预测中。

步骤4:汇总各子序列的预测结果,得最终预测结果。

步骤5:以广州塔站进出客流为例,评估基于Adam优化的WT-LSTM模型的优越性。选取平均绝对误差(E_{MAE})、均方根误差(E_{RMSE})、平均绝对百分比误差(E_{MAPE})以及决定系数(R^2)4个常用指标作为本文模型的评估指标。

$$E_{MAE} = \frac{1}{N} \sum_{i=1}^n |(y_i - y_{pi})| \quad (12)$$

$$E_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - y_{pi})^2} \quad (13)$$

$$E_{MAPE} = \frac{1}{N} \sum_{i=1}^N \left(\frac{|y_{pi} - y_i| \times 100}{y_i} \right) \quad (14)$$

$$R^2 = \frac{\sum_{i=1}^N (y_i - y_{pi})^2}{\sum_{i=1}^N (y_i - y_{pi})^2 + \sum_{i=1}^N (y_i - y_{om})^2} \quad (15)$$

式中:

y_i ——实际值;

y_{pi} ——预测值;

y_{om} ——实际值的平均值。

2 案例分析

2.1 数据分析

广州塔站为广州地铁3号线和广州地铁APM(旅客自动运输系统)线的换乘站。本文选取广州塔站3号线2021年2月26日至2021年5月8日的进出站客流作为WT-LSTM组合模型的数据来源(剔除了清明节、五一的节假日数据与4月19日的异常数据)。为保证数据的完整性,指定每日记录时段为06:00—23:00。本文选取5min的时间间隔作为短时客流的统计时长,15min的时间间隔作为短时客流的预测时长。此外,本文客流预测的分析长度为30d,即采用时刻 t 的前30d历史客流数据来实现时刻 t 的客流预测。以低频子序列 a_N 为例,自第一个样本数据块 $[(a_{1,i}, a_{2,i}, \dots, a_{30,i}), a_{31,i}]$ 起,依次下滑数据最后得 $[(a_{T-30,i}, a_{T-29,i}, \dots, a_{T-1,i}), a_{T,i}]$,这样滑动共获得 $T-30$ 个数据块。对于 a_N 的全部数据,本文以5.0:2.5:2.5的比例分成训练集、验证集和测试集。

为直观地分析广州塔站的客流特征,随机选取一周的进出站客流,如图3所示。由图3可见,广州塔站工作日进出站客流曲线的整体分布相似,具有周期

性特征。其中,工作日出站客流高峰集中在 07:30—10:00 之间,进站客流高峰则集中在 17:00—21:00 之间;周末的进出站高峰都集中在晚高峰,出站客流高峰在 17:00—21:30 之间,周六的进站客流高峰在 19:00—22:30 之间,周日的进站客流高峰在 19:00—22:00 之间。这说明广州塔站是典型的商业区。工作日

进站客流高峰的进站人数为 619 人/5 min,出站客流高峰的出站人数为 571 人/5 min;周末进站客流高峰的进站人数为 580 人/5 min,出站客流高峰的出站人数为 512 人/5 min。由图 3 可知,06:00—07:00 及 23:30—24:00 的客流量较少,因此,本文预测数据不包括这两个时间段的客流量。




图 3 广州塔站样本数据中其中一周的进出站客流量

2.2 WT-LSTM 模型参数调优

2.2.1 小波函数的选择

文献[22]指出, Daubechies (dbN) 和 Symlets (symN) 小波函数对城市轨道交通客流数据的去噪效果都很好。因此,本文分别利用 dbN 和 symN 小波函数对车站客流数据进行分解,并对出站客流的预测结果进行比对。小波分解深度为 2 层, LSTM 的优化采用 Adam 算法, LSTM 最大迭代次数为 90, LSTM 隐含层节点数为 25, 试验结果如表 1 所示。

表 1 不同小波函数性能对比

客流	小波函数	E_{MAE}	E_{RMSE}	E_{MAPE}
进站客流	db3	32.24	49.14	7.84
	db4	32.68	51.67	7.35
	db5	29.83	42.05	8.76
	sym2	49.98	71.87	13.84
	sym3	32.44	48.47	8.33
	sym4	47.10	66.74	12.23
	db3	72.92	110.30	15.18
出站客流	db4	63.01	94.28	13.02
	db5	66.13	99.21	16.67
	sym2	52.26	75.46	12.67
	sym3	70.63	105.66	14.87
	sym4	72.09	99.22	15.73

由表 1 可知:当 WT-LSTM 组合模型的小波函数为 db4 时,进出站客流数据的预测精度最高。进站客流数据的 E_{MAE} 、 E_{RMSE} 和 E_{MAPE} 分别为 32.68、51.67 和 7.35;出站客流数据的 E_{MAE} 、 E_{RMSE} 和 E_{MAPE} 分别为 63.01、94.28 和 13.02。

2.2.2 小波分解深度选择

小波分解层数选取数值越大,细节分量的低

频信息体现得越明显,但其自身的高频信息也会被渐渐分离开;同时,高频子序列也含有一定的低频信息,这会增加客流量分析的复杂程度。因此,本文分别选择两层和三层分解深度对车站的客流数据进行分解。小波函数为 db4, LSTM 的优化采用 Adam 算法, LSTM 最大迭代次数为 90, LSTM 隐含层节点数为 25, 试验结果如表 2 所示。

表 2 不同小波分解深度性能对比

客流	小波分解深度	E_{MAE}	E_{RMSE}	E_{MAPE}
进站客流	2 层	32.68	51.67	7.35
	3 层	38.00	52.07	11.63
出站客流	2 层	63.01	94.28	13.02
	3 层	67.59	104.69	16.29

由表 2 可知, WT-LSTM 组合模型的小波分解深度为 2 时,进出站客流数据的预测精度更高。

2.2.3 LSTM 优化算法选择

分别利用 RMSProp、SGD 和 Adam 算法对 LSTM 进行寻优。小波函数为 db4, 小波分解层数为 2 层, LSTM 的迭代次数 90, 隐含层节点数为 25, 试验结果如表 3 所示。由表 3 可知, Adam 算法优于 RMSProp 和 SGD 算法。

2.2.4 LSTM 节点数和迭代次数选择

LSTM 隐含层节点数和迭代次数对模型预测精度的影响很大,因此,本文首先选取隐含层节点数为 20、25、30, 迭代次数 90, 对出站客流进行预测比对。选取迭代次数为 80、85、90、95、100, 隐含层节

表 3 不同算法性能对比

客流	算法	E_{MAE}	E_{RMSE}	E_{MAPE}
进站客流	RMSProp	32.30	49.55	8.10
	SGD	47.39	69.73	11.18
	Adam	32.68	51.67	7.35
出站客流	RMSProp	75.67	106.52	16.21
	SGD	58.98	81.22	15.30
	Adam	63.01	94.28	13.02

点数 25, 进行比对 (出站客流数据的迭代次数为 95 时, 同时选取 30 的节点数。), 以获取合适的迭代次数。小波分解层数为 2 层, 小波函数位 db4, LSTM 的优化采用 Adam 算法。试验结果如表 4 和表 5 所示。

表 4 不同隐含层节点数性能对比

客流	隐含层节点数	E_{MAE}	E_{RMSE}	E_{MAPE}
进站客流	20	39.26	57.51	9.67
	25	32.68	51.67	7.35
	30	35.58	48.12	10.29
出站客流	20	61.88	87.22	14.17
	25	63.01	94.28	13.02
	30	59.21	89.45	12.73

由表 4 可知:LSTM 隐含层节点数取 25 时,进站客流数据预测精度更高;LSTM 隐含层节点数取 30 时,出站客流数据预测精度更高。由表 5 可知:LSTM 迭代次数为 95 时,进出站客流数据的预测精度更高;迭代次数为 95 时,隐含层节点数为 25 时,出站客流数据的预测精度更高。

表 5 不同迭代次数性能对比

客流	迭代次数	E_{MAE}	E_{RMSE}	E_{MAPE}
进站客流	80	30.51	44.04	8.64
	85	31.81	48.72	7.52
	90	32.68	51.67	7.35
	95	30.39	47.30	7.25
	100	46.66	59.86	14.37
出站客流	80	62.49	88.71	13.85
	85	55.84	79.33	12.79
	90	63.01	94.28	13.02
	95(节点数 25)	43.20	59.05	10.77
	95(节点数 30)	51.27	67.43	13.97
	100	62.40	94.95	15.00

综合表 1~5 参数调优可知:本文 WT-LSTM 组合模型的小波函数为 db4、小波分解层数为 2 层、LSTM 优化算法为 Adam、LSTM 最大迭代次数为 95、LSTM 隐含层节点数为 25 时,模型的预测效果最佳。此时,进站客流数据的 E_{MAE} 、 E_{RMSE} 和 E_{MAPE} 分别为 30.39、47.30 和 7.25;出站客流数据的 E_{MAE} 、 E_{RMSE} 和 E_{MAPE} 分别为 43.20、59.05 和 10.77。

2.3 LSTM 和 WT-LSTM 组合模型的比较

本文 WT-LSTM 组合模型选取小波函数为 db4,小波分解层数为 2 层,LSTM 的优化采用 Adam 算法,LSTM 最大迭代次数为 95,LSTM 隐含层节点数为 25,并与传统 LSTM 模型进行比较。经模型计算,LSTM 模型预测结果如图 4 所示,WT-LSTM 组合模型的预测结果如图 5 所示。预测性能对比如表 6 所示。




图 4 LSTM 模型的进出站客流预测结果




图 5 WT-LSTM 模型的进出站客流预测结果

表 6 LSTM 和 WT-LSTM 模型的预测性能对比					
客流	模型	E_{MAE}	E_{RMSE}	E_{MAPE}	R^2
进站客流	LSTM	49.40	76.92	11.80	0.961 3
	WT-LSTM	30.39	47.30	7.25	0.985 7
出站客流	LSTM	45.47	61.36	12.63	0.959 9
	WT-LSTM	43.20	59.05	10.77	0.963 9

由图 4 和图 5 对比可知,LSTM 模型的预测结果能够在一定程度上预测实际数据的变化,但预测误差较大;WT-LSTM 组合模型的预测结果与实际数据非常接近。由表 6 可知:WT-LSTM 组合模型相比 LSTM 模型,在 E_{MAE} 和 E_{MAPE} 方面都有较大提升, E_{RMSE} 和 R^2 也佐证了 WT-LSTM 模型的预测优势。

3 结语

针对城市轨道交通短时客流的特征,结合小波变换理论和 LSTM 模型设计了 WT-LSTM 组合预测模型,并利用 Adam 算法对 LSTM 进行优化,使用非饱和激活函数 ReLU 函数替代饱和函数激活函数 Tanh 函数。经参数调优后可得:WT-LSTM 组合模型的小波函数为 db4、小波分解层数为 2 层、LSTM 优化算法为 Adam、LSTM 最大迭代次数为 95、LSTM 隐含层节点数为 25 时,组合模型的预测效果最佳。

为了验证所建 WT-LSTM 组合模型的预测效

果,将组合模型与传统的 LSTM 模型进行比对。研究表明,WT-LSTM 组合模型在 E_{MAE} 、 E_{RMSE} 、 E_{MAPE} 和 R^2 方面均优于 LSTM 模型。WT-LSTM 组合模型的优势是,仅考虑数据本身,不用考虑站外天气、其他车站客流情况、站外大型活动等影响因素。此外,该模型对于具有时间序列特征的客流数据都具有较高的预测精度。

参考文献

[1] 四兵峰,刘剑锋,任华玲,等.城市轨道交通客流分析与预测—方法与应用[M].北京:人民交通出版社股份有限公司,2019: 53-55.

[2] 张智勇,张丹丹,贾建林,等.基于改进卡尔曼滤波的轨道交通站台短时客流预测[J].武汉理工大学学报(交通科学与工程版),2017(41): 84.

[3] 谢臻,郭建媛,秦勇.基于支持向量回归的地铁进站客流短时预测模型[J].都市快轨交通,2020(33): 92.

[4] YANG X,XUE Q,DING M,et al. Short-term prediction of passenger volume for urban rail systems: A deep learning approach based on smart-card data [J]. International Journal of Production Economics,2021,(231): 107920.

[5] LIU Y,LIU Z,JIA R. DeepPF: A deep learning based architecture for metro passenger flow prediction [J]. Transportation Research Part C: Emerging Technologies,2019(101): 18-34.

(下转第 24 页)

参考文献

- [1] 李兴高,王霆. 管线渗漏诱发地铁工程事故的安全控制技术[J]. 中国安全科学学报,2010(5):125.
 - [2] 王霆. 地铁浅埋暗挖法施工对邻近管线的影响与控制[D]. 北京:北京交通大学,2009.
 - [3] 田鲁鲁,周锦强,郭永发,等. 柱洞法施工地铁车站邻近管线变形控制技术[J]. 城市轨道交通研究,2020(7):69.
 - [4] 吴贤国,张立茂,陈跃庆,等. 地铁施工临近管线安全管理及评价标准研究[J]. 铁道标准设计,2014(9):99.
 - [5] 王雨,陈文化,崔江余,等. 地铁施工扰动下柔性管线安全评价[J]. 现代隧道技术,2016(1):83.
 - [6] 吴锋波,金淮,杨红通,等. 城市轨道交通工程周边地下管线监测控制指标[J]. 施工技术,2012(24):72.
 - [7] 中华人民共和国住房和城乡建设部,中华人民共和国国家质量监督检验检疫总局. 城市轨道交通工程监测技术规范:GB 50911—2013[S]. 北京:中国建筑工业出版社,2013.
 - [8] 中华人民共和国住房和城乡建设部. 城市地下管线探测技术规程:CJJ 61—2017[S]. 北京:中国建筑工业出版社,2017.
 - [9] 汪文强,刘争平,白国东,等. 探地雷达在地铁盾构施工滞后沉降监测中的应用研究[J]. 地球物理学进展,2016(1):354.
 - [10] 赵文,孙海霞,刘立健,等. 地下管线变形与破坏的实验与监测研究[J]. 合肥工业大学学报(自然科学版),2009(10):1485.
 - [11] 胡愈,姚爱军,张剑涛,等. 地铁盾构施工对上覆平行雨污管道影响的试验和数值分析[J]. 隧道建设,2018(5):797.
 - [12] 吴锋波,金淮,尚彦军. 城市轨道交通隧道周边地下管线变形预测研究[J]. 岩石力学与工程学报,2013(增刊2):3592.
 - [13] 王霆,罗富荣,刘维宁,等. 地铁车站洞桩法施工对地层和刚性接头管线的影响[J]. 岩土力学,2011(8):2533.
 - [14] 周先成,俞剑,黄茂松. 隧道开挖对有接头埋地管线影响的评价方法[J]. 岩土工程学报,2020(1):181.
 - [15] 中华人民共和国住房和城乡建设部,中华人民共和国国家质量监督检验检疫总局. 城市轨道交通地下工程建设风险管理规范:GB 50652—2011[S]. 北京:中国建筑工业出版社,2011.
 - [16] 刘海林,崔猛,符晓. 中心城区深基坑遇废弃防空洞处理方法研究[J]. 南昌工程学院学报,2020(6):48.
 - [17] 向维刚,马保松,赵雅宏. 给排水管道非开挖 CIPP 修复技术研究综述[J]. 中国给水排水,2020(20):1.
 - [18] 牛斌,韩聪聪,郭婷,等. 粉细砂地层单层暗挖车站工法比选研究[J]. 隧道建设,2020(增刊1):314.
 - [19] 王科甫. 超前小口径管幕在广州地铁浅埋暗挖隧道中的应用[J]. 城市轨道交通研究,2019(5):160.
 - [20] 郭远红,魏淑艳. 基于危机生命周期理论的城市地下管线事故应急问题研究[J]. 辽宁大学学报(哲学社会科学版),2017(4):18.
- (收稿日期:2021-03-25)
-
- (上接第 19 页)
- [6] LI H, WANG Y, XU X, et al. Short-term passenger flow prediction under passenger flow control using a dynamic radial basis function network [J]. Applied Soft Computing, 2019(83): 105620.
 - [7] LI Y, WANG X, SUN S, et al. Forecasting short-term subway passenger flow under special events scenarios using multiscale radial basis function networks[J]. Transportation Research Part C: Emerging Technologies, 2017(77): 306-328.
 - [8] 杨静,朱经纬,刘博,等. 基于组合模型的城市轨道交通短时客流预测[J]. 交通运输系统工程与信息,2019(19): 119.
 - [9] 沈琼. 城市轨道交通进站客流短时预测方法研究[D]. 北京:北京交通大学,2019.
 - [10] 冯诚,杨静,周雅雅,等. 基于 GWO-WNN 模型的城市轨道交通短时进站客流预测[J]. 铁道运输与经济,2019(8): 101.
 - [11] 王秋雯,陈彦如,刘媛春. 基于卷积长短时记忆神经网络的城市轨道交通短时客流预测[J]. 控制与决策,2020(9): 1.
 - [12] WU Y, TAN H. Short-term traffic flow forecasting with spatial-temporal correlation in a hybrid deep learning framework[J]. Computer Science, arXiv:1612.01022(2016).
 - [13] PENG H, WANG H, DU B, et al. Spatial temporal incidence dynamic graph neural networks for traffic flow forecasting[J]. Information Sciences, 2020, (521): 277-290.
 - [14] SUN Y, LENG B, GUAN W. A novel wavelet-SVM short-time passenger flow prediction in Beijing subway system[J]. Neuro-computing, 2015(166): 109-121.
 - [15] 龙小强,李捷,陈彦如. 基于深度学习的城市轨道交通短时客流量预测[J]. 控制与决策,2019(34): 1589.
 - [16] 李兆丰,倪少权,孙克洋,等. 基于多特征融合的城市轨道交通短时客流预测[J]. 交通运输工程与信息学报, 2020(18): 97.
 - [17] 杨静,代盛旭,张红亮,等. 大型活动散场期间地铁车站短时进站客流预测[J]. 科学技术与工程,2021(21): 2042.
 - [18] 杨静,张洪亮,邓进. 城市轨道交通客流特性与预测研究[M]. 北京:人民交通出版社股份有限公司,2020: 74-75.
 - [19] NELSON D, PEREIRA A, OLIVEIRA R. Stock market's price movement prediction with LSTM neural networks[C]. IEEE. 2017 International Joint Conference on Neural Networks (IJCNN). Anchorage, AK, USA: IEEE, 14-19 May 2017: 1419-1426.
 - [20] 谢明磊. 基于 LSTM 网络的住宅负荷短期预测[J]. 广东电力,2019(32): 108.
 - [21] Tang Z, Yin H, Yang C, et al. Predicting the electricity consumption of urban rail transit based on binary nonlinear fitting regression and support vector regression[J]. Sustainable Cities and Society, 2021(66): 102690.
 - [22] 求森. 基于小波分析和神经网络的城市轨道交通客流时间序列预测[D]. 北京:北京交通大学,2017.
- (收稿日期:2021-02-21)