

地铁站点短时客流变化规律分析及预测方法<sup>\*</sup>黎家靖<sup>1</sup> 张 宁<sup>2</sup> 温龙辉<sup>2</sup> 李兆君<sup>3</sup>

(1. 中铁第四勘察设计院集团有限公司, 430063, 武汉; 2. 东南大学智能运输系统研究中心, 210018, 南京;

3. 滁州市滁宁城际铁路开发建设有限公司, 239001, 滁州//第一作者, 助理工程师)

**摘 要** 目的: 地铁站点短时客流预测是地铁车站运营管理的重要组成部分之一, 精准的客流预测结果可为地铁车站的运营计划提供数据支撑, 需对地铁站点短时客流的预测方法进行系统、深入的研究。方法: 以地铁南京南站(四线换乘站)为例, 分析了该站点短时客流的变化规律, 发现其在一周内存在 3 种日客流发展模式。基于此, 使用 STL(时间序列分解)算法和 EMD(经验模态分解)算法对该站的原始进站客流进行双层分解, 结合 BiLSTM(双向长短期记忆网络)构建了该站的客流预测组合模型。将该组合模型的客流预测流程细分为 3 个阶段, 选取合适的参数值, 对输出的预测结果进行对比分析。最后对不同时间粒度的客流统计间隔进行试验, 以验证客流统计间隔和模型预测效果的关系。结果及结论: STL-EMD-BiLSTM 组合模型在 3 类日客流发展模式下的平均绝对百分比误差分别为 5.0%、6.3%、6.3%。与其余 5 种预测模型相比, STL-EMD-BiLSTM 组合模型的均方根误差、平均绝对误差和平均绝对百分比误差均为最优, 这说明该组合模型的有效性和准确性。客流统计间隔增加, 模型的预测效果随之提升。

**关键词** 地铁; 短时客流; 变化规律; 双层分解; 组合模型  
中图分类号

DOI: 10.16037/j.1007-869x.2023.11.007

## Analysis and Prediction Methods of Short-term Passenger Flow Changes at Metro Station

LI Jiajing, ZHANG Ning, WEN Longhui, LI Zhaojun

**Abstract** Objective: Short-term station passenger flow prediction is one of the important components of metro operation management. Accurate prediction can provide data support for the operation planning of metro stations. Therefore, systematic and in-depth research on short-term passenger flow prediction methods at metro stations is needed. Method: Taking metro Nanjingnan Station (a four-line transfer station) as an example, the changing patterns of short-term passenger flow at this

station are analyzed, and three different daily patterns are identified within a week. Based on this, the original inbound passenger flow is decomposed into two layers using the STL (seasonal and trend decomposition using Loess) algorithm and the EMD (Empirical Mode Decomposition) algorithm. Combined with BiLSTM (Bidirectional Long Short-Term Memory) network, a composite model for prediction is constructed. The passenger flow prediction process of this composite model is divided into three stages, suitable parameter values are selected to compare and analyze the predicted results. Finally, experiments are conducted on different time granularity of passenger flow statistics intervals to verify the relationship between passenger flow statistics intervals and the effectiveness of the prediction model. Result & Conclusion: The mean absolute percentage error of the STL-EMD-BiLSTM combined model for the three types of daily passenger flow development patterns are 5.0%, 6.3%, and 6.3%, respectively. Compared with the other five prediction models, the root-mean-square error, mean absolute error, and mean absolute percentage error of the STL-EMD-BiLSTM combined model are the best, indicating the effectiveness and accuracy of this combined model. As the interval of passenger flow statistics increases, the predictive performance of the model improves accordingly.

**Key words** metro; short-term passenger flow; change law; tow-layer decomposition; combined model

**First-author's address** China Railway Siyuan Survey and Design Group Co., Ltd., 430063, Wuhan, China

地铁站点短时客流预测是指对地铁站点未来某一时间段内(一般不超过 30 min)的客运量进行预测。如何在已有历史客流数据的基础上, 准确把握地铁站点的客流变化规律并对客运量进行预测, 已成为目前业界的研究热点之一。短时客流预测方法目前一般分为 3 种: ①基于数理统计的预测方法, 如 ARIMA(自回归移动平均)模型<sup>[1]</sup>、

<sup>\*</sup> 国家重点研发计划项目(2020YFB1600700)

SVM(支持向量机)模型<sup>[2]</sup>等;②基于人工智能的预测方法,如BP(反向传播)神经网络模型<sup>[3]</sup>、DL-STM(深度长短期记忆网络)模型<sup>[4]</sup>等;③组合预测方法,如EMD(经验模态分解)-BP组合模型<sup>[5]</sup>等。此外,EMD算法<sup>[6]</sup>、CEEMDAN-VMD(完全总体经验模态分解-变分模态分解)双层分解算法<sup>[7]</sup>等算法可降低了原始客流数据的噪声,提高预测的准确率。

本文使用组合模型方法对地铁站点进行短时客流预测,并分析原始地铁站点的短时客流变化规律。基于STL(时间序列分解)算法和EMD算法对客流序列进行双层分解,以抑制噪声干扰,再利用BiLSTM(双向长短期记忆网络)算法进行客流预测,进而构建STL-EMD-BiLSTM组合模型,实现对地铁站点短时进站量的预测。

### 1 地铁站点短时进站量变化规律分析

地铁站点短时进站量受工作日、双休日客流特征的影响,在一周内呈现出不同的日客流发展模式,且同一日客流发展模式下站点客流序列的相关程度较高,不同日客流发展模式下站点客流序列变化趋势各不相同<sup>[8]</sup>。

地铁南京南站是南京地铁1号线、3号线、S1线、S3号线的四线换乘站。本文以该站为案例,对该站的进站量数据进行研究,使用Pearson相关系

数对数据进行相关性分析,以探究一周内日均进站量间的相关性,其结果如图1所示。由图1可知:从地铁南京南站的日均进站量看,周一、周二、周三、周四两两之间、周五与周日之间的Pearson相关系数均大于0.90,周六与其他日的Pearson相关系数均小于0.85。




图1 地铁南京南站一周内日均进站量间的相关性  
Fig. 1 Correlation of daily average inbound volume within a week in Nanjingnan Metro Station

设定Pearson相关系数大于等于0.90为相关性显著,因此可得出地铁南京南站一周内存在3类不同的日客流发展模式:第1类日客流(周一至周四)发展模式;第2类日客流(周五及周日)发展模式;第3类日客流(周六)发展模式。

基于2019年3月的进站客流数据(见图2)对地铁南京南站作进一步的客流特征分析。




图2 不同日客流发展模式下地铁南京南站每日进站量随运营时段变化曲线(2019年3月)  
Fig. 2 Curves of daily inbound volume of Nanjingnan Metro Station with operating hours under different daily passenger flow development models (March, 2019)

1) 如图2b)所示,第1类日客流发展模式下,周一上午有明显的早高峰时段,周二至周四上午并无明显的早高峰时段;周一至周四的17:30—19:00均有明显的客流晚高峰,该时段与工作日通勤客流下班时段相对应。

2) 如图2c)所示,第2类日客流发展模式下,

类日客流发展模式,这主要是由于周五和周日部分乘客下班后倾向于选择参加社交活动。

3) 如图2d)所示,在第3类日客流发展模式下,周六乘客倾向于选择外出游玩,进而呈现出通勤客流减少、非通勤客流增加的特征;且在08:30—13:00期间出现持续客流高峰,该时段与周六的日间活动出发客流时段相对应。

## 2 STL-EMD-BiLSTM 组合模型构建

若直接采用地铁站原始的短时进站量序列数据进行客流预测,原始客流数据序列的自身噪声及随机波动会对客流预测产生干扰。因此,先使用 STL 算法和 EMD 算法对原始客流序列进行双层分解,以减少其噪声干扰,再采用 BiLSTM 算法进行客流预测。

### 2.1 STL 算法

STL 算法将原始时间序列  $Y_v$  分解为趋势项  $T_v$ 、季节项  $S_v$  和余量项  $R_v$ ,其计算式为:

$$Y_v = T_v + S_v + R_v \quad (1)$$

式中:

- $T_v$ ——时间序列的长期特征;
- $S_v$ ——时间序列的周期性特征;
- $R_v$ ——时间序列的随机噪声扰动。

### 2.2 EMD 算法

EMD 算法将原始信号分解为  $N$  个 IMF(本征模态函数)分量及 1 项残差分量,其计算式为:

$$f(t) = \sum_{i=1}^N C_i(t) + r(t) \quad (2)$$

式中:

- $f(t)$ ——原始信号,本文指由原始进站客流序列经过 STL 分解后所得到的余量项  $R_v$ ;
- $t$ ——信号采样时刻;
- $i$ ——IMF 分量的序号;
- $C_i(t)$ ——第  $i$  个 IMF 分量,用以反映  $f(t)$  在不同频段下的振荡变化情况;
- $r(t)$ ——残差分量,用以反映  $f(t)$  的缓慢变化趋势。

### 2.3 BiLSTM 算法

BiLSTM 算法解决了 LSTM(长短期记忆)网络仅通过单向时序输入更新和传递参数的问题,由 1 个前向 LSTM 网络和 1 个反向 LSTM 网络组成。这 2 个 LSTM 网络相互独立,可从正反 2 个方向对历史数据进行训练,以获取更多有效信息。

### 2.4 STL-EMD-BiLSTM 组合模型

图 3 为基于 STL-EMD-BiLSTM 组合模型的地铁站点短时客流预测流程。

该流程分为 3 个阶段:

- 1) 第 1 阶段,处理原始数据,构建地铁站点进站量时间序列,并根据客流变化规律对其进行分类。
- 2) 第 2 阶段,利用 STL 算法将客流序列分解为趋势项、季节项及余量项,并对各项数据进行白噪

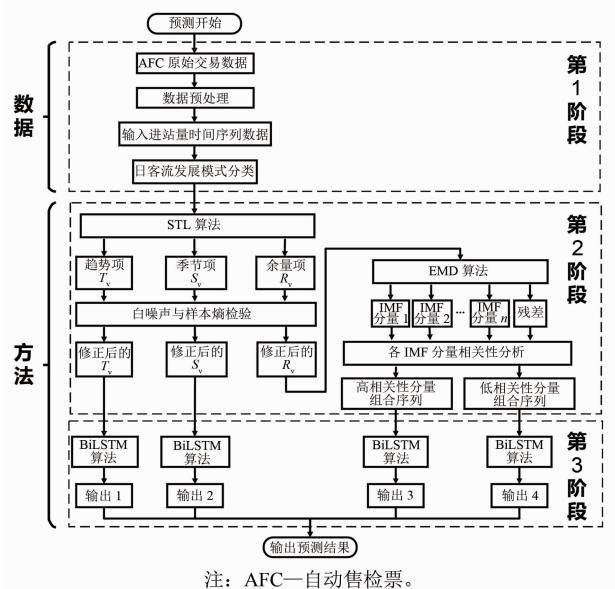


图 3 基于 STL-EMD-BiLSTM 组合模型的地铁站点短时客流预测流程

Fig. 3 Forecast process of metro station short-time passenger flow based on the STL-EMD-BiLSTM combined model

声与样本熵检验;再通过 EMD 算法对余量项进行二次分解,得到多个 IMF 分量及残差,并对各 IMF 分量进行相关性分析。

3) 第 3 阶段,将分解后的趋势项、季节项及由余量项分解得到的各 IMF 分量送入 BiLSTM 模型中,完成训练和预测,输出预测结果。

## 3 实例分析

选取 2019 年 3 月 1 日—2019 年 3 月 31 日南京地铁 AFC 系统中地铁南京南站的原始数据作进一步分析。该站客流数据庞大且变化规律复杂,如能准确预测该站短时客流,对本文所建组合模型算法有一定代表意义。本文设定该站每日客流的统计间隔为 30 min,运营时段为 06:30—23:30。

### 3.1 客流数据分解

将 30 min 作为一个统计时段,可将每日运营时间分为 34 个统计时段。以第 1 类日客流的日进站量为例进行分析,2019 年 3 月 1 日—3 月 31 日第 1 类日客流对应的总天数为 16 d,将这 16 d 所有统计时段(共计 544 个)的数据进行分析,其 STL 分解结果如图 4 所示,其中:趋势项  $T(t)$  反映了客流在一个循环周期(周一至周四,共 4 d)内的大致变化趋势,季节项  $S(t)$  反映了客流在 1 d 内的波动情况,余量项  $R(t)$  反映了客流的整体随机性。

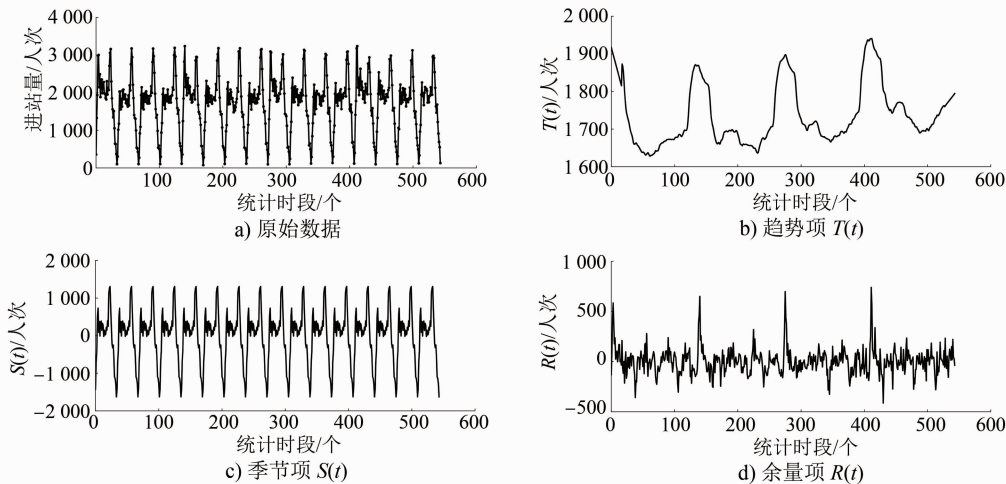


图 4 第 1 类日客流日进站量的 STL 分解结果截图

Fig. 4 Screenshot of STL decomposition results for daily inbound volume of the 1<sup>st</sup> passenger flow model

3 类日客流发展模式下趋势项、季节项及余量项的白噪声及样本熵检验结果如表 1 所示。分析白噪声检验结果可知:白噪声检测值均远小于阈值(0.05),故这 3 项分量均不是白噪声序列,可用来对数据进行预测。分析样本熵检验结果可知: $T(t)$ 、 $S(t)$  分解较为完全; $R(t)$  分解不完全,仍包含部分未完全分解的客流信息,因此需对  $R(t)$  进行二次分解,以最大程度挖掘其隐含信息。

对  $R(t)$  进行二次分解,得到 7 个 IMF 分量和 1 项残差。仍以第 1 类日客流发展模式下分解得到的  $R(t)$  为例,其 EMD 分解结果如图 5 所示,将每个

IMF 分量按从高频到低频依次排列,以反映  $R(t)$  的不同时间局部特征。

表 1 各分量的白噪声及样本熵检测值  
Tab. 1 White noise value and sample entropy value of components

日客流 发展模式 类别	各分量的白噪声			各分量的样本熵		
	$T(t)$	$S(t)$	$R(t)$	$T(t)$	$S(t)$	$R(t)$
第 1 类	$7.0\times10^{-119}$	$7.4\times10^{-88}$	$9.5\times10^{-40}$	0.2	0.6	1.7
第 2 类	$2.0\times10^{-75}$	$4.8\times10^{-63}$	$9.6\times10^{-20}$	0.3	0.4	1.9
第 3 类	$1.5\times10^{-38}$	$3.0\times10^{-31}$	$2.2\times10^{-6}$	0.2	0.5	1.6

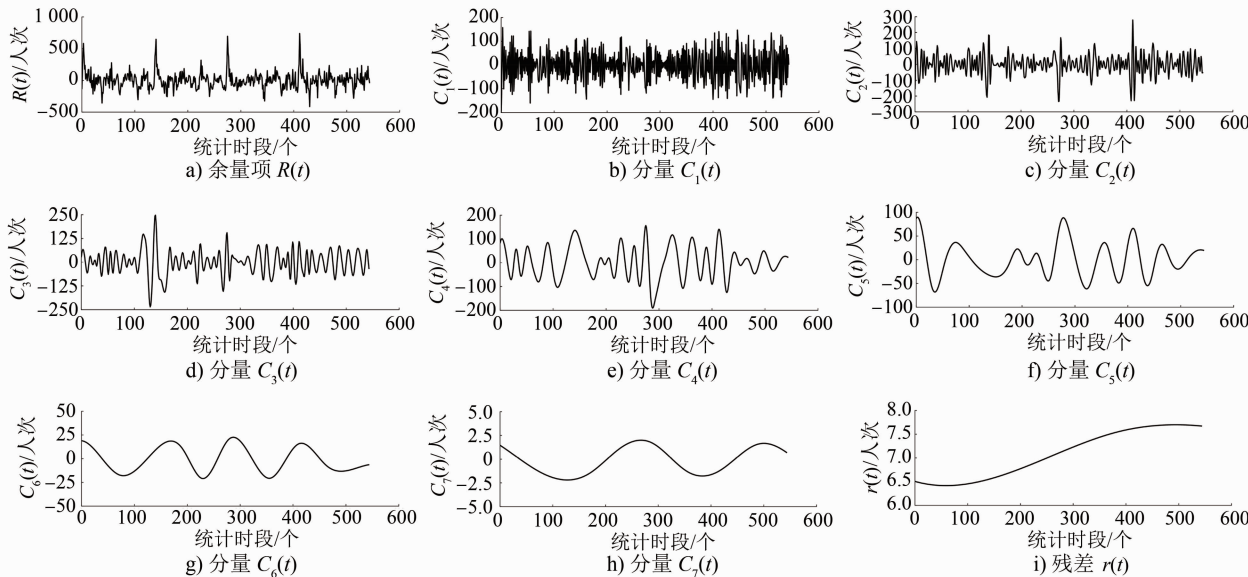


图 5 第 1 类日客流余量项  $R(t)$  的 EMD 分解结果

Fig. 5 EMD decomposition results for remainder component  $R(t)$  of the 1<sup>st</sup> passenger flow model



### 3.2 BiLSTM 模型输入

设  $d$  为日客流发展模式的循环周期,  $k$  为日期序号,  $j$  为时段序号。将预测日的前  $d$  日相同时段的客流数据  $[x_{k-d,j} \ x_{k-d+1,j} \cdots x_{k-1,j}]$ , 以及该预测日预

$$\mathbf{X} = \begin{bmatrix} x_{k-d,j-q} & x_{k-d+1,j-q} & \cdots & x_{k-1,j-q} & x_{k,j-q-q} & x_{k,j-q-q+1} & \cdots & x_{k,j-q-1} & x_{k,j-q} \\ \vdots & \vdots & & \vdots & \vdots & \vdots & & \vdots & \vdots \\ x_{k-d,j-2} & x_{k-d+1,j-2} & \cdots & x_{k-1,j-2} & x_{k,j-q-2} & x_{k,j-q-1} & \cdots & x_{k,j-3} & x_{k,j-2} \\ x_{k-d,j-1} & x_{k-d+1,j-1} & \cdots & x_{k-1,j-1} & x_{k,j-q-1} & x_{k,j-q} & \cdots & x_{k,j-2} & x_{k,j-1} \\ x_{k-d,j} & x_{k-d+1,j} & \cdots & x_{k-1,j} & x_{k,j-q} & x_{k,j-q+1} & \cdots & x_{k,j-1} & x_{k,j} \end{bmatrix} \quad (3)$$

式(3)中:前  $d+q$  列为输入数据;最后一列为输出数据,即最终的预测结果输出数据。

### 3.3 关键参数取值

#### 3.3.1 $d$ 的取值

考虑到一周内存在 3 类日客流发展模式,这 3 类模式的循环周期分别为 4 d、2 d 及 1 d,即 3 类日客流发展模式的循环周期下  $d$  值分别设为  $d_1=4$  d、 $d_2=2$  d、 $d_3=1$  d。

#### 3.3.2 $q$ 的取值

为确定  $q$  值大小,分别取  $q=1$ 、 $q=2$ 、 $q=3$  及  $q=4$  进行试验。设 BiLSTM 层数为  $L$ ,令  $L=3$ ,激活函数选择 Relu,优化函数选择 Adam,取学习率  $l_r=0.01$ ,计算得到  $q$  取不同值时模型的平均绝对误差  $E_{\text{MAE}}$  如表 2 所示。由表 2 可知:在第 1 类、第 2 类日客流发展模式下,  $q=2$  时模型的  $E_{\text{MAE}}$  最小,这说明这 2 种模式下预测时段进站量与该时段紧邻的前 2 个时段有较大关联;在第 3 类日客流发展模式下,  $q=1$  时模型的  $E_{\text{MAE}}$  最小,这是由于周六进站量波动幅度不大,预测时段进站量受前一时段影响较大。综上,3 类日客流发展模式下  $q$  值分别设为  $q_1=2$ 、 $q_2=2$ 、 $q_3=1$ 。

#### 3.3.3 $L$ 的取值

在确定  $q$  值的基础上,选择  $L=1$ 、 $L=2$ 、 $L=3$ 、 $L=4$ 、 $L=5$  及  $L=6$  进行试验,其余参数取值不变,计算可

测时间点的前  $q$  个时段(每个时段为 30 min)的客流数据  $[x_{k,j-q} \ x_{k,j-q+1} \cdots x_{k,j-1}]$  作为模型输入,用以预测该预测日预测时间点下一时段的站点进站量,其数据集  $\mathbf{X}$  为:

得  $L$  取不同值时模型的  $E_{\text{MAE}}$  如表 3 所示。由表 3 可知:模型的  $E_{\text{MAE}}$  与  $L$  不是简单线性关系,增加  $L$ ,并不一定能提高模型的预测效果。为此,3 类日客流发展模式下  $L$  值分别设为  $L_1=3$ 、 $L_2=6$ 、 $L_3=4$ 。

表 2 不同  $q$  值下模型的平均绝对误差

Tab. 2 Average absolute error of the model with different  $q$  values

日客流发展模式类别	不同 $q$ 值下模型的 $E_{\text{MAE}}$			
	$q=1$	$q=2$	$q=3$	$q=4$
第 1 类	91.2	82.2	82.6	128.0
第 2 类	130.2	107.6	109.9	133.9
第 3 类	115.8	124.1	124.4	139.7

表 3 不同  $L$  值下模型的平均绝对误差

Tab. 3 Average absolute error of the model with different  $L$  values

日客流发展模式类别	不同 $L$ 值下模型的 $E_{\text{MAE}}$					
	$L=1$	$L=2$	$L=3$	$L=4$	$L=5$	$L=6$
第 1 类	81.1	80.2	79.8	91.2	92.5	82.3
第 2 类	127.4	115.9	112.2	151.2	122.1	97.7
第 3 类	118.3	122.2	118.4	105.8	107.4	121.5

### 3.4 预测结果分析

为验证 STL-EMD-BiLSTM 组合模型的有效性,另外选取了 5 种模型,将这 6 种模型的预测结果与真实值进行对比试验,其对比结果如图 6 所示。




图 6 不同类日客流发展模式下地铁南京南站短时客流各算法预测值与真实值的对比

Fig. 6 Algorithms comparison of predicted and real short-term passenger flow values of Nanjingnan Metro Station under different daily passenger flow development models

由图 6 可知:①直接对原始客流序列进行预测的模型(包括 SVM 模型、BP 模型、LSTM 模型及 BiLSTM 模型),其预测效果相对较差;② STL-BiLSTM 组合模型通过序列分解有效抑制了噪声干扰,其预测效果较优;③STL-EMD-BiLSTM 模型由于使用了双层分解算法,对客流变化规律的把握最全面,从直观上看,其预测结果最贴近真实客流曲线,拟合效果最优。

使用  $E_{MAE}$ 、均方根误差  $E_{RMSE}$ 、平均绝对百分比误差  $E_{MAPE}$  作为这 6 种模型的评价指标,不同模型下地铁南京南站各日客流发展模式的评价指标值如表 4 所示。

表 4 不同模型下地铁南京南站各日客流发展模式的评价指标值

Tab. 4 Evaluation index values for each passenger flow category under different models in Nanjingnan Metro Station

模型类型	日客流发展模式类别	评价指标值		
		$E_{RMSE}$	$E_{MAE}$	$E_{MAPE}/\%$
SVM	第 1 类	154.0	125.2	8.8
	第 2 类	231.3	189.9	10.0
	第 3 类	207.7	170.6	11.2
BP	第 1 类	154.2	116.5	8.3
	第 2 类	206.6	166.9	8.6
	第 3 类	195.1	166.0	10.9
LSTM	第 1 类	138.2	103.5	7.3
	第 2 类	177.3	138.7	7.3
	第 3 类	177.4	141.3	7.6
BiLSTM	第 1 类	123.7	95.4	5.7
	第 2 类	158.2	126.9	7.0
	第 3 类	172.9	137.5	7.3
STL-BiLSTM	第 1 类	117.1	85.8	5.9
	第 2 类	132.6	109.2	6.8
	第 3 类	129.0	107.4	6.9
STL-EMD-BiLSTM	第 1 类	101.9	77.8	5.0
	第 2 类	121.4	94.3	6.3
	第 3 类	123.1	98.1	6.3

由表 4 可知:①SVM 模型和 BP 模型的预测效果最差,其原因在于这 2 种模型难以有效提取客流序列中的时间特征和前后关联信息;②与 LSTM 模型相比,BiLSTM 模型能从正反 2 个方向训练和更新参数,能捕获更多历史数据的有效信息,因此 BiLSTM 模型效果更优;③STL-BiLSTM 组合模型使用了 STL 算法,以避免直接对原始客流序列进行预测,因此其预测效果优于 BiLSTM 模型;④STL-EMD-BiLSTM 组合模型的  $E_{RMSE}$ 、 $E_{MAE}$ 、 $E_{MAPE}$  均优

于其余 5 个模型,这说明了原始客流时间序列进行 STL 和 EMD 双层分解能有效削弱噪声,提高预测精度。

为探究时间粒度对客流预测精度的影响,分别取每日客流统计间隔为 5 min、15 min 及 30 min 3 种粒度,应用 STL-EMD-BiLSTM 组合模型得到不同时间粒度下模型的  $E_{MAPE}$  如表 5 所示。

表 5 不同时间粒度下地铁南京南站基于 STL-EMD-BiLSTM 组合模型的客流预测平均绝对百分比误差

Tab. 5 Average absolute percentage error of passenger flow forecast for Nanjingnan Metro Station based on STL-EMD-BiLSTM combined model under different intervals

时间粒度/min	日客流发展模式类别	$E_{MAPE}/\%$
5	第 1 类	8.3
	第 2 类	9.4
	第 3 类	9.9
15	第 1 类	6.2
	第 2 类	7.9
	第 3 类	8.6
30	第 1 类	5.0
	第 2 类	6.3
	第 3 类	6.3

由表 5 可知:当时间粒度由 5 min 增至 30 min 时,STL-EMD-BiLSTM 组合模型在 3 类日客流发展模式下的  $E_{MAPE}$  分别由 8.3%、9.4%、9.9% 减少至 5.0%、6.3%、6.3%。这是因为随着客流统计间隔的增加,每日进站量时间序列相似性增加,客流变化规律得以加强,模型的预测效果也随之提升。

#### 4 结语

本文探讨了地铁站点短时客流的变化规律,得出一周内 3 种不同的日客流发展模式的结论。使用 STL 和 EMD 算法对原始的客流序列进行双层分解,有效抑制了噪声干扰。本文搭建的 STL-EMD-BiLSTM 组合模型在地铁南京南站的实际应用中表明:3 类日客流发展模式下的  $E_{MAPE}$  分别为 5.0%、6.3% 及 6.3%;与另选的 5 个预测模型相比,该组合模型的  $E_{RMSE}$ 、 $E_{MAE}$ 、 $E_{MAPE}$  均为最优。当客流统计间隔由 5 min 增至 30 min 时,基于 STL-EMD-BiLSTM 组合模型得到地铁南京南站的客流预测结果的  $E_{MAPE}$  逐渐减小,且预测值与  $E_{MAPE}$  呈现出负相关关系。

在下一阶段的研究中,应综合考虑天气、节假

日等因素,对地铁站点的进站客流变化规律和预测方法展开更为深入、系统的研究。

## 参考文献

- [1] 王夏秋,张宁,王健. 基于季节指数的城市轨道交通月度客流预测方法[J]. 城市轨道交通研究,2018,21(10):25.  
WANG Xiaqiu, ZHANG Ning, WANG Jian. Forecasting method of monthly urban rail transit passenger flow based on seasonal index[J]. Urban Mass Transit, 2018,21(10):25.
- [2] 谢倩,叶红霞. 基于支持向量机的节假日进出站客流预测方法[J]. 城市轨道交通研究,2018,21(8):26.  
XIE Qiao, YE Hongxia. Forecast for holiday passenger flow at urban rail transit station based on support vector machine model[J]. Urban Mass Transit, 2018,21(8):26.
- [3] 侯晨煜,孙晖,周艺芳,等. 基于神经网络的地铁短时客流预测服务[J]. 小型微型计算机系统,2019,40(1):226.  
HOU Chenyu, SUN Hui, ZHOU Yifang, et al. Prediction service of subway short-term passenger flow based on neural network[J]. Journal of Chinese Computer Systems, 2019,40(1):226.
- [4] 崔洪涛,陈晓旭,杨超,等. 基于深度长短期记忆网络的地铁进站客流预测[J]. 城市轨道交通研究,2019,22(9):41.  
CUI Hongtao, CHEN Xiaoxu, YANG Chao, et al. Forecast of subway inbound passenger flow based on DLSTM recurrent network[J]. Urban Mass Transit, 2019,22(9):41.
- [5] 傅晨琳,黄敏,沙志仁. 基于 EEMD-BP 方法的城市轨道交通进站客流短期预测[J]. 铁道运输与经济,2020,42(3):105.  
FU Chenlin, HUANG Min, SHA Zhiren. Short-term forecast of passenger flow into an urban rail transit station based on EEMD-BP[J]. Railway Transport and Economy, 2020,42(3):105.
- [6] 赵阳阳,夏亮,江欣国. 基于经验模态分解与长短时记忆神经网络的短时地铁客流预测模型[J]. 交通运输工程学报,2020,20(4):194.  
ZHAO Yangyang, XIA Liang, JIANG Xinguo. Short-term metro passenger flow prediction based on EMD-LSTM[J]. Journal of Traffic and Transportation Engineering, 2020,20(4):194.
- [7] 胡进宝. 基于双层分解和核函数极限学习机的城市轨道交通短时客流预测[D]. 北京:北京交通大学,2017.  
HU Jinbao. Short-term forecasting using a hybrid model based on two-layer decomposition technique and kernel-based extreme learning machine [D]. Beijing: Beijing Jiaotong University, 2017.
- [8] 林培群,陈丽甜,雷永巍. 基于 K 近邻模式匹配的地铁客流量短时预测[J]. 华南理工大学学报(自然科学版),2018,46(1):50.  
LIN Peiqun, CHEN Litian, LEI Yongwei. Short-term forecasting of subway traffic based on K-nearest neighbour pattern matching[J]. Journal of South China University of Technology (Natural Science Edition), 2018,46(1):50.
- (收稿日期:2021-06-29)
- (上接第 35 页)
- [5] 王建波,彭龙镖,李娜,等. 基于 PCA-RBF 神经网络的地铁车站火灾风险评估[J]. 工业安全与环保,2017,43(9):67.  
WANG Jianbo, PENG Longbiao, LI Na, et al. Fire risk evaluation of subway station based on PCA-RBF neural network[J]. Industrial Safety and Environmental Protection, 2017, 43(9):67.
- [6] HOLLING C S. Resilience and stability of ecological systems[J]. Annual Review of Ecology and Systematics, 1973, 4: 1.
- [7] LYU Wendong, ZHAO Yang, WEI Yuan. On resilient risk management-organizational management technology for coping with uncertain situations[J]. Management World, 2019, 35(9):116.
- [8] ELA B S. Urban rail operators in Turkey: organisational reform in transit service provision and the impact on planning, operation and system performance[J]. Journal of Transport Geography, 2016, 54: 464.
- [9] 黄浪,吴超,王秉. 系统安全韧性的塑造与评估建模[J]. 中国安全生产科学技术,2016,12(12):15.  
HUANG Lang, WU Chao, WANG Bing. Modeling on shaping and assessment of system safety resilience[J]. Journal of Safety Science and Technology, 2016, 12(12):15.
- [10] FRANCIS R, BEKERA B. A metric and frameworks for resilience analysis of engineered and infrastructure systems[J]. Reliability Engineering & System Safety, 2014, 121: 90.
- (收稿日期:2021-06-23)

欢迎订阅《城市轨道交通研究》

服务热线 021—56830728