

基于时间序列分解方法的城市轨道交通大客流预测方法

郑俊锋¹ 方旭峰² 王晨阳¹

(1. 合肥市轨道交通集团有限公司, 230001, 合肥; 2. 西南交通大学交通运输与物流学院, 611756, 成都//第一作者, 高级工程师)

摘要 目的:大型活动举办当日,周边城市轨道交通车站易产生瞬时进站大客流,需研究大型活动引发大客流的预测方法,以便及时调整运输组织方案,有效处置可预见性大客流。方法:介绍了城市轨道交通大客流定义;分析了大型活动引发可预测性大客流的客流结构特征、空间特征和时间特征;介绍了大型活动引发可预测性大客流的预测方法,并通过实例进行了预测方法的应用验证。结果及结论:根据大客流是否可预测,可分为可预测大客流和不可预测大客流;大型活动引发可预测性大客流具有明显的结构特征、空间特征和时间特征;实例验证结果表明,所提出的基于 STL (Seasonal and Trend decomposition using Loess) 的时间序列分解方法的 LightGBM 方法(即 STL-LightGBM),预测精度较高,有助于充分掌握大型活动引发大客流的特征与规律。

关键词 城市轨道交通;大客流;时间序列;客流预测

中图分类号 U442.55

DOI:10.16037/j.1007-869x.2023.08.031

Prediction Method for Urban Rail Transit Large Passenger Flow Based on Time Series Decomposition Method

ZHENG Junfeng, FANG Xufeng, WANG Chenyang

Abstract Objective: On days of large-scale events taking place, URT (urban rail transit) stations in surrounding areas often experience instantaneous spike of inbound passenger flow. It is necessary to study the prediction methods for large passenger flow resulting from large-scale events, so that transportation organization plans are promptly adjusted and foreseeable large passenger flow can be effectively handled. Method: The definition of URT large passenger flow is introduced. The structural, spatial, and temporal characteristics of the foreseeable large passenger flow induced by large-scale events are analyzed, the prediction methods for which are presented, and their application is verified through practical examples. Result & Conclusion: Based on the predictability of large passenger flow, two categories of foreseeable and unforeseeable large

passenger flows can be derived. Foreseeable large passenger flow from large-scale events exhibits distinct structural, spatial, and temporal characteristics. The results of practical example verification indicate that the proposed prediction method based on STL (Seasonal and Trend decomposition using Loess) combined with LightGBM (also known as STL-LightGBM) achieves high prediction accuracy. This method helps to fully understand the characteristics and patterns of large passenger flow induced by large-scale events.

Key words urban rail transit; large passenger flow; time series; passenger flow prediction

First-author's address Hefei Rail Transit Group Co., Ltd., 230001, Hefei, China

体育赛事、演唱会、音乐节及博览会等大型活动日益增多,活动散场后观众离场时间集中,对于活动场馆周边的城市轨道交通车站,易产生大量瞬时进站大客流,使车站作业、列车运营面临极大挑战。当大客流出现,原列车运行计划与变化的客流需求不匹配时,将造成乘客在车站聚集、列车超载、妨碍列车前方车站乘客乘车等影响。提前预测大型活动引发大客流的发生时间与强度,以便城市轨道交通运营企业及时调整运输组织方案,有效处置可预见性大客流,是亟待解决的问题。

1 城市轨道交通大客流定义

根据研究表明,当车站站台等候的乘客密度达到甚至超过 2 人/ m^2 时,乘客的移动速度会受到极大的阻碍^[1],并会对乘客的感受造成明显负面影响^[2]。基于上述标准,本文对城市轨道交通大客流定义为:在一个发车间隔内,在城市轨道交通车站站台某一方向区域等待的乘客不小于 2 人/ m^2 ,且进入该站乘客人数无明显减少趋势的情况。

大客流的生产具有多样性和复杂性,是外部环境因素和乘客个体出行选择综合影响的结果。根据大客流是否可预测,将大客流分为可预测大客流和不可预测的大客流^[3]。

1.1 可预测大客流

可预测大客流是由可预测的乘客出行行为引发的大客流。如计划举办的体育赛事、演唱会等大型活动,活动散场后,乘客在短小时内大量进入活动场馆周边车站,产生大客流。另因节假日等乘客出行需求激增,在特定时段,以及在商业中心、景区附近车站也可能产生大客流。该类大客流可以通过活动前的乘客出行 OD(起讫点)、活动时间、活动规模、活动地点进行预测,具有较好的可预测性,故将该类客流作为本文的研究对象。

1.2 不可预测大客流

不可预测大客流是由城市轨道交通设施突发故障、恶劣天气等不可预测原因引发的大客流。当城市轨道交通设施突发故障时,城市轨道交通运输能力下降,造成乘客滞留车站、列车拥挤度上升、车站乘客承载量达到阈值,产生大客流。当天气恶劣时,道路交通的乘客会向城市轨道交通转移,极大地提高了城市轨道交通的客流量。该类客流由于引发原因的突然性和不可预知性,客流的 OD 和时间也很难预知,因此对于该类大客流,本文不予考虑。

2 大型活动引发可预测大客流特征分析

城市轨道交通可预测大客流具有强度大、持续时间可预测、影响范围大的特点,城市轨道交通运营企业若能准确识别该特征,就能提前调整列车运行计划,以应对该类大客流。

本文从客流结构,以及空间和时间三个角度分析大客流发生前后车站进出站客流量变化规律。以合肥市某周六(为当月 21 日)举办的一次大型演唱会为例,以演唱会举办地为中心的 1 km 范围内,有 1 座城市轨道交通非换乘车站 P 站。该活动举行时间为 20:00—22:00,活动规模为 12 000 人。

2.1 客流结构特征

在大型活动举办前后,根据乘客出行目的的可将城市轨道客流划分为大型活动客流、通勤客流、其他出行客流。其中,通勤客流具有较为显著的周期性,其他客流的随机性较强,而大型活动客流根据活动安排,是可预见的。

大型活动开始前,大量乘客在特定时段从特定车站出站,短小时内出站客流量的大幅提高是大型活动客流的显著表征之一。由于乘客是随着列车到站而分批次出站的,因此一般情况下,乘客出站过程不会产生乘客滞留。大型活动结束后,通过公共交通聚集的乘客一般会选择原交通工具返回,因此举办地周边车站进站客流量短小时内会大幅提高,该车站活动前出站客流量的提高部分与活动后进站客流量的提高部分是正相关的,该部分客流与活动举办地点、举办时间、活动规模具有高度的相关性。

2.2 空间特征

P 站及其所在线路客流量较大的 25 座车站大型活动前后 1 h 客流变化情况如图 1 所示。




图 1 大型活动前后 1 h 车站客流变化情况

Fig. 1 Changes in passenger flow within 1 hour before and after the large-scale event

由图 1 可知,P 站在活动前 1 h 内的出站客流量和活动后 1 h 内的进站客流量均远大于其余各站,该特征可用于大型活动周边车站大客流的识别与预测。

2.3 时间特征

为进一步验证大型活动引发大客流的特征,选取大型活动的当天(21 日),以及该日的前一周(14 日)和前两周(7 日)的客流进行对比,时间粒度为

15 min。

2.3.1 出站客流

图 2 为 P 站及与其相邻的 O 站和 Q 站的出站客流量变化情况。

图 3 为 P 站及与其相邻的 O 站和 Q 站的进站客流量变化情况。

于这 3 座车站所在的区域均为金融中心,发挥的功能相同。

2.3.2 进站客流

图 3 为 P 站及与其相邻的 O 站和 Q 站的进站客流量变化情况。

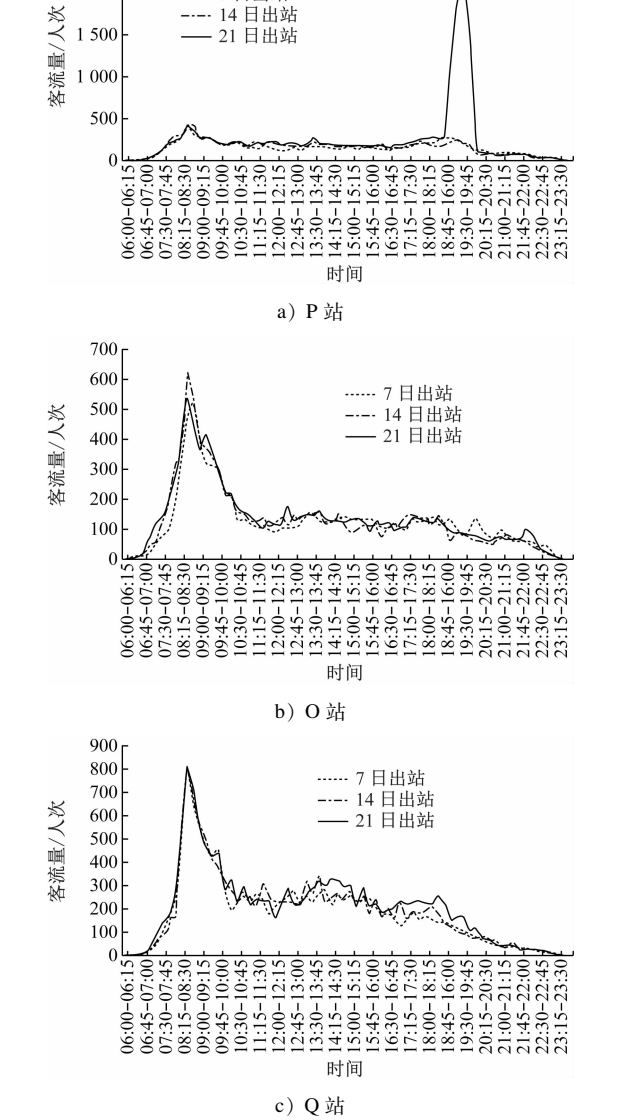


图 2 P 站及其相邻车站三天(含大型活动当天)出站客流量变化情况

Fig. 2 Changes in outbound passenger flow at P Station and adjacent stations over three days (including the day of the large-scale event)

由图 2 可知,仅 P 站活动当天(21 日)19:00—20:00 出站客流量激增,其余时段各站的出站客流量特征基本一致。由此可知:O 站与 Q 站的客流量具有相似的变化规律;如果忽略 P 站 19:00 后的大客流,3 座车站客流量的整体变化规律较为一致,由

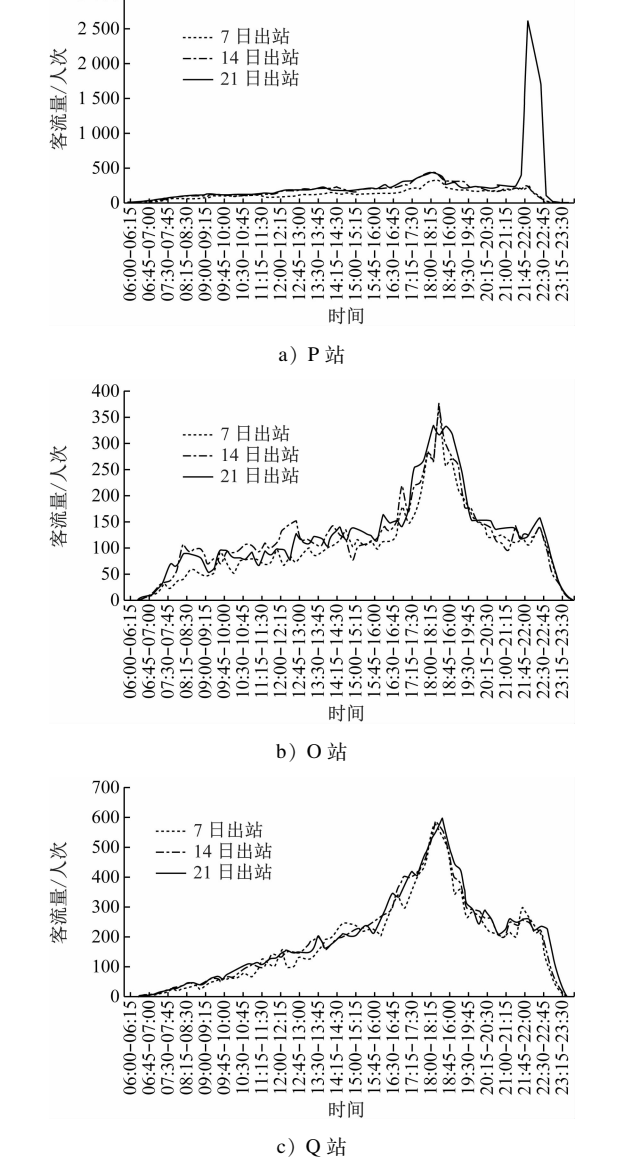


图 3 P 站及其相邻车站三天(含大型活动当天)进站客流量变化情况

Fig. 3 Changes in inbound passenger flow at P Station and adjacent stations over three days (including the day of the large-scale event)

由图 3 可知,仅 P 站活动当天(21 日)22:00—23:00 进站客流量激增,其余时段各站的进站客流量特征基本一致。

根据上述分析,归纳大型活动引发的大客流规

律为:

1) 大型活动开始前,大客流发生车站的出站客流有别于通勤客流,具有极大的强度,且车站靠近活动举办地点。

2) 大型活动结束后,大客流产生在靠近活动举办地点的车站,进站客流强度与该站活动开始一段时间的出站客流强度关联性强。

3) 大型活动引发的大客流通常集中于举办地附近个别车站,对其余车站的影响较小。

4) 大客流产生后将持续一段时间,该时间长度与车站运能、大客流强度、线路运能有关,一般可持续 1~2 h。

3 大型活动引发可预测大客流预测方法

目前的客流预测方法主要有:通过构建基于时间序列^[4-10]的 ARIMA、ARIMAX 等数理统计模型,使用支持向量机(SVM)^[11-12]、长短期神经网络(LSTM)^[13-15]及其他机器学习方法^[16-18]的机器学习模型。

数理统计模型对于趋势性强的客流数据预测精度较高,但存在需要连续稳定客流时序数据、仅能捕捉客流数据线性规律、对客流非线性特征及随机性把握不足等局限性。传统的机器学习模型对于单一环境下的客流预测精度较高,例如 LSTM 模型,其对未来客流的预测完全基于客流的历史信息,对规律变化客流的预测性较好,但在实际应用中,因大型活动的规模、时间、地点,以及当天的天气情况不尽相同,这些因素对客流的系统性影响也不尽相同,其更高精度的客流特点难以被传统机器学习模型捕捉。

为进一步提高多种因素系统影响下客流预测精度,本文在上述两类预测模型的基础上,拟使用基于 STL(Seasonal and Trend decomposition using Loess)的时间序列分解方法的 LightGBM 方法(即 STL-LightGBM)进行大客流预测。

3.1 基于 STL 的时间序列分解方法

时间序列是按时间顺序索引的一系列数据点,一个时间序列通常可以被拆分为趋势量(T)、季节量(S)、周期量(C)和随机量(I)。

在进行时间序列分析时,采用时间序列分解方法能够降低噪声干扰,可提高预测的精确度。时间序列分解方法一般可分为加法模型(见式(1))和乘法模型(见式(2))。

$$Y_t = T_t + S_t + C_t + I_t \quad (1)$$

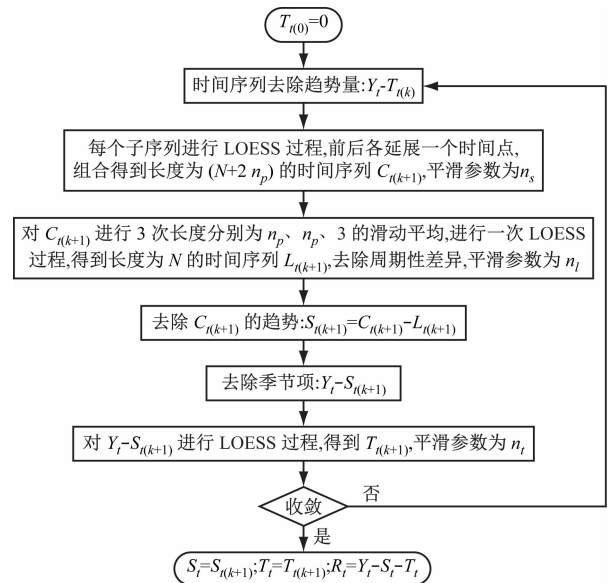
$$Y_t = T_t S_t C_t I_t \quad (2)$$

式中:

Y_t ——原时间序列在 t 时刻的值;

T_t 、 S_t 、 C_t 、 I_t ——分别为时间序列在 t 时刻的趋势量、季节量、周期量和随机量。

本文使用基于 STL 的时间序列分解方法,通过鲁棒局部加权回归平滑化时间序列后将其分解得到趋势量、季节量和随机量。STL 分为外循环与内循环,外循环计算鲁棒性权重,内循环计算时间序列的分解量,其流程如图 4 所示。



注: k —循环的次数; N —时间序列样本数; n_p —时间序列的周期(一个周期有几个样本); n_s 、 n_l 、 n_t —在不同步骤中截取的进行加权滑动平均的数据长度; L_t — t 时刻, 去除周期性差异后的时间序列; R_t — t 时刻, 删除趋势量与季节量后的时间序列; LOESS—局部加权回归。

图 4 STL 循环流程图

Fig. 4 Flow chart of STL loop

如果样本的趋势较强,则当删除数据中的季节分量后,变动幅度应比残差项大,可以用 R_t 的方差与 $T_t + R_t$ 的方差表示。若时间序列的趋势较弱,则两个方差大致相等。据此,趋势强度定义如式(3)所示,其给定了趋势强度的衡量标准,其值在 0~1 之间。

$$F_T = \max[0, 1 - \text{Var}(R_t)/\text{Var}(T_t + R_t)] \quad (3)$$

式中:

F_T ——时间序列的趋势强度。

与此相似,季节性的强度定义如式(4):

$$F_S = \max[0, 1 - \text{Var}(R_t)/\text{Var}(S_t + R_t)] \quad (4)$$

式中：
 F_s ——时间序列的季节性强度。
在时间序列中季节性一般呈现周期性变化的规律,因此季节性周期中的波峰大体上也是固定的,故只需要找到季节性周期中的最大值就可以确定波峰期。

以活动当日 P 站进站客流为例,将研究时间段平滑参数设定为 4,将原客流基于 SLT 的时间序列分解方法分解后的结果如图 5 所示。




图 5 大型活动当日 P 站进站客流量基于 STL 时间序列分解方法分解结果

Fig. 5 Decomposition results of inbound passenger flow at P Station on the day of the large-scale event based on STL method

图 5 分别为原始时间序列趋势量,以及分解后的趋势量、季节量和随机量,由此可得趋势量有两个峰值,与上文的 P 站大客流特征分析一致。当研究时段设定为 1 h 时,季节量具有明显的周期性;观察随机量发现,在前 60 个时间段,4 个随机量为一组呈现周期性变化规律,在大型活动结束后随机量的波动较大。

3.2 大客流特征工程

在模型训练前需要对一些特殊特征进行编码。以大型活动产生的大客流为例,其特征值包括但不限于预测时间编码、活动时段特征编码、活动前 t 内出站客流编码、天气编码和气温编码。

3.2.1 预测时间编码
以 15 min 为时间粒度对一日内的城市轨道交通运营时间进行编码时,按照时间顺序进行整数编码,结果如表 1 所示。

表 1 预测时间编码

Tab. 1 Encoding for predicted timestamps	
时间	时间编码
[6:00,6:15)	1
[6:15,6:30)	2
⋮	⋮
[23:45,24:00)	72

3.2.2 活动时段特征编码
对于大型活动时间的编码,以其持续时间段的时间编码差值表示,活动持续中对应编码为 0。如活动持续时间为 19:00—21:45,其对应的时间编码为 53—63,则对应活动编码如表 2 所示。

表 2 大型活动时间编码

Tab. 2 Encoding for large-scale event timestamps	
大型活动时间	活动时间编码
[18:45,19:00)	-1
[19:00,19:15)	0
[19:15,19:30)	0
⋮	⋮
[21:30,21:45)	0
[21:45,22:00)	1

3.2.3 活动前 t 内出站客流编码
由上文分析可知,大型活动前 q 时间内出站人数与大型活动结束后进站客流量有直接关系,因此也需作为一个特征参与进站客流量的预测。将编号为 $i-d-q$ 时间段的该站出站客流量作为特征,计算公式为:

$$P_i = P_{\text{out},i-d-q}$$

(5)

式中：
 P_i ——编号为 i 的时间段对应的客流特征数值；
 $P_{\text{out},i-d-q}$ ——编号为 $i-d-q$ 时间段对应的出站客流量；
 d ——活动持续的时间段数量。

3.2.4 天气编码
天气对乘客出行行为具有一定的影响。恶劣天气下,乘客出行减少,公共交通客流压力较小。

根据天气对乘客出行影响程度的编码方案如表 3 所示。按照天气对乘客出行的正面影响和负面影响,分别赋值正数和负数,影响程度越大则绝对值越大。

表 3 天气编码

Tab.3 Encoding for weather	
天气情况	天气编码
暴雨、暴雪、冰雹	-4
大雨、大雪、大风	-3
中雨、中雪	-2
小雨、小雪	-1
阴、多云	0
晴	1

3.2.5 气温编码

人体舒适温度为 25 ℃,以此标准,对气温进行编码,气温偏离 25 ℃越多,值越低,如式(6)所示。

$$U_{c,i} = - | V_{T,i} - 25 \text{ }^{\circ}\text{C} | \tag{6}$$

式中:

$U_{c,i}$ ——编号为 i 的时间段对应的气温特征值;
 $V_{T,i}$ ——编号为 i 的时间段对应的实际气温。

3.3 LightGBM 模型

LightGBM 模型的表达式见文献[19]。

第 z 次迭代时模型目标为最小化损失函数:

$$\begin{aligned} \text{obj}_z = & \sum_{u=1}^N L(y_u, \hat{y}_{u,z}) + \sum_{j=1}^z \Omega(f_j) = \\ & \sum_{u=1}^N L(y_u, \hat{y}_{u,z-1} + f_z(x_u)) + \Omega(f_z) + \\ & \sum_{j=1}^{z-1} \Omega(f_j) \end{aligned} \tag{7}$$

式中:

y_u ——第 u 个样本值, $u=1,2,\cdots,N$;
 $\hat{y}_{u,z}$ ——由 z 个弱学习器计算得到的第 u 个样本的预测值;
 $L(y_u, \hat{y}_{u,z})$ ——损失函数;
 $\Omega(f_j)$ 、 $\Omega(f_2)$ ——正则项;
 $f_z(x_u)$ ——第 z 个弱学习器;
 x_u ——第 u 个样本的特征值。

$L(y_u, \hat{y}_{u,z})$ 一般可以用真实值与预测值的差的平方表示,如式(8)所示。

$$L(y_u, \hat{y}_{u,z}) = (y_u - \hat{y}_{u,z})^2 \tag{8}$$

$\Omega(f_j)$ 用以表示模型的复杂度,将其加入目标函数可以避免某一特征对应的参数(权重)过大的问

题,LightGBM 使用 L2 正则化,即参数的平方和,如式(9)所示:

$$\Omega(f_j) = \gamma W + \frac{1}{2} \lambda \sum_{j=1}^W w_j^2 \tag{9}$$

式中:

γ, λ ——超参数;
 W ——叶子节点数;
 w_j ——节点 j 的参数。

式(7)用二阶泰勒公式展开可简化为式(10):

$$\begin{aligned} \text{obj}_z = & \sum_{u=1}^N \left[L(y_u, \hat{y}_{u,z-1}) + g_u f_z(x_u) + \right. \\ & \left. \frac{1}{2} h_u f_z^2(x_u) \right] + \Omega(f_z) + c \end{aligned} \tag{10}$$

式中:

g_u ——损失函数的一阶导数;
 h_u ——损失函数的二阶导数;
 c ——常数。

将式(8)和式(9)代入式(10)可进一步简化为下式:

$$\text{obj}_z = \gamma W + \sum_{j=1}^W \left[w_j G_j + \frac{1}{2} w_j^2 (\lambda + H_j) \right] \tag{11}$$

其中, $G_j = \sum_{u \in I_j} g_u, H_j = \sum_{u \in I_j} h_u, I_j$ 表示叶子节点 j 的样本集合。根据上式可以解得节点 j 参数的最优值 $w_{j,o}$,如式(12):

$$w_{j,o} = - G_j / (H_j + \lambda) \tag{12}$$

3.4 性能评价指标

预测误差是检验预测模型效果的最重要评价指标,本文选取平均绝对误差 (E_{MAE})、均方误差 (E_{MSE}) 作为预测模型的评价标准,这两个指标能够反映真实客流量和预测客流量之间的偏差情况,两者值越大则说明误差越大,值越小则误差越小。计算公式为:

$$E_{MAE} = N^{-1} \sum_{u=1}^N | \hat{y}_u - y_u | \tag{13}$$

$$E_{MSE} = N^{-1} \sum_{u=1}^N (\hat{y}_u - y_u)^2 \tag{14}$$

4 实例应用

以合肥市某周六(为当月 21 日)举办的一次大型演唱会为实例。将大型活动的时间、规模、开始时间、结束时间,开始前 1.0 h 和 0.5 h 内出站客流

量、邻站 15 min 内客流量、天气、平均气温,以及本站客流趋势量、季节量、随机量作为特征进行模型训练。为了防止过拟合,超参数设置如下:最大深度为 11,叶子节点数量为 1 024($\leq 2^{11}$)个,最小样本量为 12 个。使用时间段为大型活动当月 1 日至 20 日的城市轨道交通客流数据作为训练集,预测时间间隔为 15 min。在运营时段内一天有 72 条数据,共 2 160 个样本数据。

在相同超参数设定下,STL-LightGBM 与 LightGBM 对同一数据集(大客流出现时间编码为 64—67)的预测结果如图 6 所示。由图 6 可见,虽然模拟结果均较为符合实际值,但使用 STL-LightGBM 方法的预测数据更为贴近实际值。

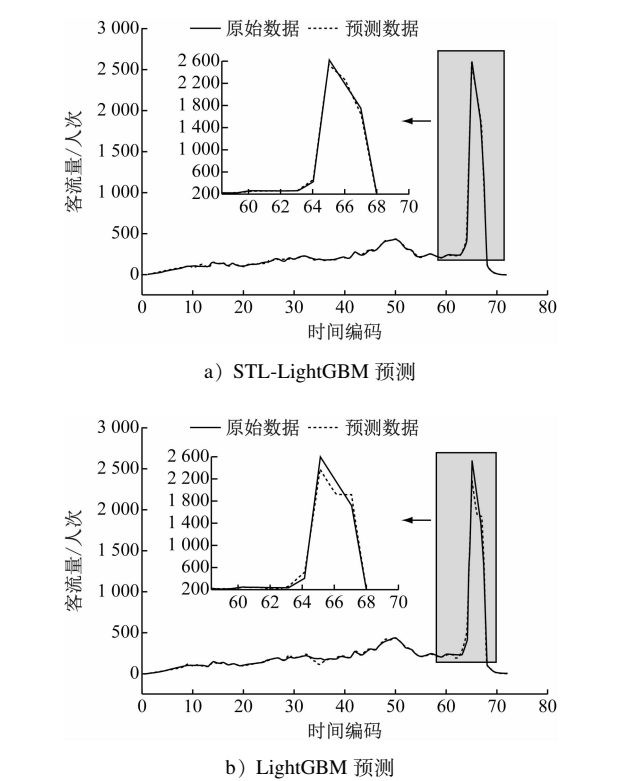


图6 STL-LightGBM 与 LightGBM 预测结果对比
Fig.6 Comparison of STL-LightGBM and LightGBM prediction results

进一步进行性能评价,将目前短期客流预测常用的 LSTM 与 LightGBM 方法和本文提出的 STL-LightGBM 方法对同一测试集客流数据的预测结果进行对比,结果如表 4 所示。由表 4 可见,在相同情况下,本文提出的大客流预测方法的 E_{MAE} 和 E_{MSE} 在三者中均为最低,表明 STL-LightGBM 预测精度更高,有助于充分掌握大客流的特征与规律。

表 4 不同预测方法的客流预测结果对比
Tab.4 Comparison of passenger flow prediction results by different prediction methods

预测方法	E_{MAE}	E_{MSE}
LSTM	13.04	712.96
LightGBM	11.84	445.21
STL-LightGBM	9.75	307.06

5 结语

本文在总结分析大客流特征的基础上,提出了 STL-LightGBM 城市轨道交通站点大客流预测方法。通过对客流时间序列的分解,获得其趋势量、季节量和随机量,并作为大客流的特征输入机器学习模型。该大客流预测方法的预测误差较小,预测效果较好。

参考文献

[1] CAREY M. A model and strategy for train pathing with choice of lines, platforms, and routes[J]. Transportation Research Part B: Methodological, 1994, 28(5): 333.

[2] 刘建荣,黄玲. 地铁拥挤度和出行者异质性对时间价值的影响[J]. 交通运输系统工程与信息, 2020, 20(2): 122.
LIU Jianrong, HUANG Ling. Impact of metro's in-vehicle crowding and commuters' heterogeneity on value of time[J]. Journal of Transportation Systems Engineering and Information Technology, 2020, 20(2): 122.

[3] 侯宇菲. 城市轨道交通突发大客流站车协同优化处置模型与方法研究[D]. 深圳: 深圳大学, 2019.
HOU Yufei. Study on the model and method of coordinated optimal disposal of sudden large passenger flow in urban rail transit [D]. Shenzhen: Shenzhen University, 2019.

[4] 闻克宇,赵国堂,何必胜,等. 基于改进迁移学习的高速铁路短期客流时间序列预测方法[J]. 系统工程, 2020, 38(3): 73.
WEN Keyu, ZHAO Guotang, HE Bisheng, et al. An improved transfer learning-based time series prediction method for the high-speed rail short-term volume[J]. Systems Engineering, 2020, 38(3): 73.

[5] 赵建东,朱丹,刘佳欣. 基于时间序列分解与门控循环单元的地铁换乘客流预测[J]. 华南理工大学学报(自然科学版), 2022, 50(5): 22.
ZHAO Jiandong, ZHU Dan, LIU Jiaxin. Metro transfer passenger flow prediction based on STL-GRU[J]. Journal of South China University of Technology (Natural Science Edition), 2022, 50(5): 22.

[6] 唐继强,钟鑫伟,刘健,等. 基于时间序列季节分类模型的轨道交通客流短期预测[J]. 重庆交通大学学报(自然科学

- 版), 2021, 40(7): 31.
- TANG Jiqiang, ZHONG Xinwei, LIU Jian, et al. Short-term forecast of rail transit passenger flow based on time series seasonal classification model[J]. Journal of Chongqing Jiaotong University (Natural Sciences), 2021, 40(7): 31.
- [7] 潘杉. 基于时间序列的铁路客流量预测[D]. 广州: 华南理工大学, 2017.
- PAN Shan. Railway passenger flow forecast based on time series [D]. Guangzhou: South China University of Technology, 2017.
- [8] 任鹏. 基于时间序列的机场短时段值机客流量预测[D]. 天津: 中国民航大学, 2019.
- REN Peng. Short-term check-in passenger flow forecast of airport based on time series [D]. Tianjin: Civil Aviation University of China, 2019.
- [9] 熊智, 钟少波, 宋敦江, 等. 城市轨道交通客流量时间序列分段拟合方法[J]. 中国安全科学学报, 2018, 28(11): 35.
- XIONG Zhi, ZHONG Shaobo, SONG Dunjiang, et al. A method of fitting urban rail transit passenger flow time series [J]. China Safety Science Journal, 2018, 28(11): 35.
- [10] 衡红军, 任鹏. 基于时间序列的机场短时段值机客流量预测[J]. 计算机仿真, 2020, 37(2): 26.
- HENG Hongjun, REN Peng. Short-term passenger flow forecasting for the check-in process in the airport based on time series [J]. Computer Simulation, 2020, 37(2): 26.
- [11] 张和杰, 马维华. 基于时空特征的地铁客流预测[J]. 计算机科学, 2019, 46(7): 292.
- ZHANG Hejie, MA Weihua. Subway passenger flow forecasting model based on temporal and spatial characteristics [J]. Computer Science, 2019, 46(7): 292.
- [12] 冯树民, 刘浩, 李来成. 雨雪天气下轨道交通客流预测模型[J]. 哈尔滨工业大学学报, 2022, 54(9): 1.
- FENG Shumin, LIU Hao, LI Laicheng. Prediction model of rail transit passenger flow in rain and snow weather [J]. Journal of Harbin Institute of Technology, 2022, 54(9): 1.
- [13] 李艳, 夏增刚, 陈爱玲. 基于多尺度组合的旅游客流预测方法[J]. 统计与决策, 2020, 36(22): 177.
- LI Yan, XIA Zenggang, CHEN Ailing. Prediction method of tourist flow based on multi-scale combination [J]. Statistics and Decision, 2020, 36(22): 177.
- [14] 张建旭, 宾科, 蒋雨洋. 考虑轨道出行时空分布的断面客流预测[J]. 重庆理工大学学报(自然科学), 2022(6): 164.
- ZHANG Jianxu, BIN Ke, JIANG Yuyang. Cross-section passenger flow forecast considering the spatial and temporal distribution of urban rail travel [J]. Journal of Chongqing University of Technology (Natural Science), 2022(6): 164.
- [15] 张国赞, 金辉. 基于改进 PSO-LSTM 模型的城市轨道交通站点客流预测[J]. 计算机应用与软件, 2021, 38(12): 110.
- ZHANG Guoyun, JIN Hui. Passenger flow prediction of urban rail transit stations based on improved PSO-LSTM model [J]. Computer Applications and Software, 2021, 38(12): 110.
- [16] ZHANG Z, WANG C, GAO Y, et al. Short-term passenger flow forecast of rail transit station based on MIC feature selection and ST-LightGBM considering transfer passenger flow [J]. Scientific Programming, 2020, 29: 1.
- [17] ZHOU W, WANG W, ZHAO D. Passenger flow forecasting in metro transfer station based on the combination of singular spectrum analysis and AdaBoost-weighted extreme learning machine [J]. Sensors, 2020, 20(12): 3555.
- [18] 王雪琴, 许心越, 伍元凯, 等. 基于混合深度学习模型的城轨短时客流预测[J]. 铁道科学与工程学报, 2022, 19(12): 3557.
- WANG Xueqin, XU Xinyue, WU Yuankai, et al. Short-term passenger flow forecasting of urban rail transit based on hybrid deep learning model [J]. Journal of Railway Science and Engineering, 2022, 19(12): 3557.
- [19] 何芸. 基于 LGBM 模型的城市道路交通流量预测研究[J]. 电子技术与软件工程, 2022(3): 259.
- HE Yun. Research on urban road traffic Flow prediction based on LGBM model [J]. Electronic Technology & Software Engineering, 2022(3): 259.

(收稿日期:2023-04-18)

交通运输部发布城市轨道交通 6 月份数据

据交通运输部消息:2023 年 6 月份,31 个省(自治区、直辖市)和新疆生产建设兵团共有 54 个城市开通运营城市轨道交通线路 295 条,运营里程 9 728.3 km。实际开行列车 312 万列次,完成客运量 24.4 亿人次,进站量 14.7 亿人次。客运量环比减少 0.5 亿人次,降低 2.2%;客运量同比增加 6.7 亿人次、增长 37.7%;较 2019 年月均客运量增加 4.5 亿人次,增长 22.6%。客运强度平均水平为 0.523 万人次/(km·d),较 2019 年全年客运强度平均水平降低 4.3%。新增运营里程 75.4 km,其中,新增运营线路 3 条(苏州地铁 11 号线、西安地铁 16 号线和兰州地铁 2 号线),新增运营区段 2 个(长春地铁 4 号线南延线、西安地铁 2 号线二期南北延伸段)。

(来源:交通运输部官网)