

# 大型活动散场期间城市轨道交通大客流 时空分布预测及其应用\*

周 峰<sup>1</sup> 王文昱<sup>1</sup> 赵 周<sup>1</sup> 文旭光<sup>2</sup>

(1. 同济大学道路与交通工程教育部重点实验室, 201804, 上海;

2. 广西中国-东盟综合交通国际联合重点实验室, 530299, 南宁)

**摘 要** [目的]随着市民对文娱生活的多样化需求日益渐增,各城市举办的大型活动数量不断增加,大型活动诱发的大客流会对城市轨道交通常态运营造成干扰,存在安全风险,因此需从历史数据中挖掘客流特征,并提出客流预测方法,为轨道交通运营部门在大型活动期间的行车计划提供科学的决策支持。[方法]从多源影响因素的挖掘与分析出发,收集了起始车站、馆站距离、日期类型、天气类型、活动类型、活动等级、售票规模、出站人数等信息作为特征变量,考虑到随着时间推移可获得的自变量信息数量和精确度越来越高,设计了滚动数据驱动的 XGBoost 预测模型;基于乘客的出行轨迹,提出了大型活动散场大客流时空分布分析方法。以某城市车站附近场馆举办大型活动为例,验证所提预测方法的准确性。[结果及结论]所提客流预测方法在 OD (起讫点)层面、线路层面、进站量层面均取得了较好的预测精度,能够为车站客流管控和网络运营调整提供决策依据。**关键词** 城市轨道交通;大型活动散场;大客流;时空分布预测

中图分类号 U293.13

DOI:10.16037/j.1007-869x.2025.05.005

## Prediction and Application of Spatiotemporal Distribution of Large Passenger Flow in Urban Rail Transit During Crowd Dispersal of Large Scale Events

ZHOU Feng<sup>1</sup>, WANG Wenyu<sup>1</sup>, ZHAO Zhou<sup>1</sup>, WEN Xuguang<sup>2</sup>

(1. The Key Laboratory of Road and Traffic Engineering, Ministry of Education, Tongji University, 201804, Shanghai, China; 2. Guangxi Key Laboratory of International Join for China-ASEAN Comprehensive Transportation, Nanning University, 530299, Nanning, China)

**Abstract** [Objective] With the citizens' daily increasing demand for the diversification of cultural and recreational activities, the number of large-scale events held in cities is continu-

ously increasing. The large passenger flows induced by these events can disrupt the normal operation of urban rail transit and pose safety risks. Therefore, it is necessary to extract passenger flow characteristics from historical data and propose passenger flow prediction methods to provide scientific decision-making support for rail transit operation authorities during large-scale events. [Method] Starting from the exploration and analysis of multi-source influencing factors, information such as origin stations, venues-station distances, date types, weather types, event types, event scale, ticket sales volume, and exit passenger numbers is collected as feature variables. Considering that the amount of independent variable information available is increasing and its accuracy improves over time, a rolling data-driven XGBoost prediction model is designed. Based on passenger travel trajectories, a spatiotemporal distribution analysis method for large passenger flows during the crowd dispersal of large-scale events is proposed. The accuracy of the proposed prediction method is verified using the case of a large-scale event held at a venue close to station in a certain city. [Result & Conclusion] The proposed passenger flow prediction method achieves high prediction accuracy at the OD (origin-destination) level, line level, and entry volume level. It can provide a decision-making basis for station passenger flow control and network operation adjustments.

**Key words** urban rail transit; crowd dispersal of large-scale event; large passenger flow; spatiotemporal distribution prediction

近年来,城市轨道交通的运营场景日益复杂多样,非周期性的偶发大客流数量也随之增长。大型活动诱发的大客流会在极小的时空范围内迅速集聚,不仅对车站和本线造成巨大的客运压力,还会通过换乘站向网络中的其他线路传播,加剧运能与运量之间的矛盾。因此,事先把握计划性大客流的

\* 国家自然科学基金项目(72171174);广西科技计划项目(桂科 AA21077011)

特征,能够使运营方及时制定针对性、前瞻性的应对策略,防范安全隐患。

短期客流预测主要是在运营阶段为运营计划的制定与调整提供依据。常态客流受职住分离和作息规律的影响,具有较强的重复性和规律性。部分非常态大客流的诱因是供给侧发生了变化,如设备故障等;另有部分非常态大客流的诱因是需求侧发生了变化,如举办体育赛事、交易会、博览会等<sup>[1-2]</sup>。大型活动的种类多样,所吸引的客流不尽相同,故大型活动诱发的大客流具有动态性和随机性特点,对客流预测方法提出了更高的要求。

目前,针对短期客流预测的方法主要有:回归模型、多项式分布滞后模型、时间序列、灰色预测理论,以及深度学习模型,如神经网络模型、XGBoost算法等<sup>[1-8]</sup>。在进行短期客流预测时,交通系统的外部影响因素数据可以提高客流预测能力,如节假日信息、社交网络数据、天气状况、活动规模等<sup>[3-8]</sup>。

已有文献研究大多关注城市轨道交通的稳态

客流分析,对客流预测场景的划分尚不精细,考虑的影响因素并不全面;针对大型活动的客流预测仅关注了进站、出站客运量指标<sup>[5,9]</sup>,其预测结果对现场运营的指导作用未得到充分发挥。

鉴于此,本文分析了大型活动诱发性大客流的内部及外部影响因素,提出了一种基于多源数据驱动的大客流预测方法,从时空维度对直接预测结果进行计算与应用。本文研究可为车站客流管控和网络运营调整提供决策支撑。

## 1 问题描述

某城市轨道交通车站在大型活动举办日的进出站客运量如图1所示。由图1可知:在大型活动开始前较长的时间范围内,客流陆续到达并出站,对车站客运量的冲击较小;当大型活动结束后,大客流集中进站并离开,在较小的时空范围内呈现客流激增态势,存在安全隐患。因此,本文的研究对象为大型活动的散场大客流。




图1 某城市轨道交通车站在大型活动举办日的进出站客运量

Fig. 1 Inbound and outbound passenger volume at a certain urban rail transit station on the day of a large-scale event

根据现场经验,选取8类数据作为大型活动诱发性大客流的可能影响因素。

1) 起始车站(承担大型活动散场客流进入城市轨道交通系统的车站)。一般来说,起始车站不同,代表举办大型活动的场馆有所不同,其活动性质可能有所不同,活动受众也相应呈现出一定的差异性。

2) 场馆与车站间的距离(以下简称“馆站距离”)。对于场馆附近只有一个车站的情况,场馆离

车站越近,则城市轨道交通对大型活动客流的分担率就可能越高。对于场馆附近有多多个车站的情况,选择最近的车站上下车的乘客可能更多。

3) 日期类型。由于客观作息时限限制,同类型大型活动在工作日或节假日吸引的客流可能有所不同。

4) 天气类型。天气可能会影响乘客的出行意愿,也可能会改变城市轨道交通的客流分担率。

5) 活动类型。同一个场馆可能举办不同类型的活动,进而吸引不同来源地的客流。

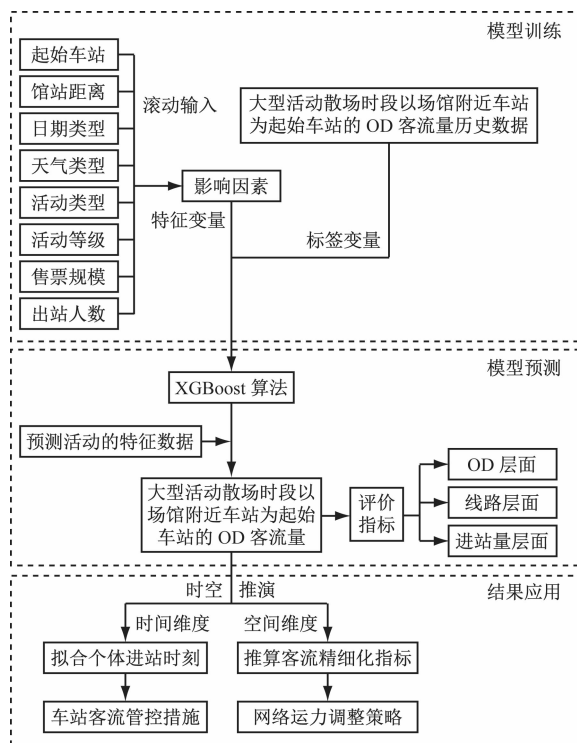
6) 活动等级。同类型活动的受欢迎程度可能有所不同,进一步细分活动等级可以反映参与大型活动的人数规模。

7) 售票规模。活动举办方的售票情况能够直接反映活动规模,但该数据在活动开始前是持续变化的,且不易获取,有条件的情况下可以将该指标纳入考虑范围。

8) 出站人数。活动开始前一定时间范围内的出站人数能够直接反映城市轨道交通将对该活动承担的客运量,在可行性和时效性允许的情况下可以纳入考虑范围。

## 2 模型构建

本文构建的大型活动诱发性大客流预测模型架构示意图如图2所示。



注:OD为起讫点。

图2 大型活动诱发性大客流预测模型架构示意图

Fig.2 Schematic diagram of the prediction model framework for large-scale passenger flows induced by large-scale events

### 2.1 基于XGBoost算法的OD客流预测

2016年,文献[10]提出了XGBoost算法,其是一种基于梯度提升树算法改进的非线性集成学习

算法。XGBoost算法的基本原理及运算步骤为:

步骤1 输入训练样本集合,在特征空间中计算切分数据集的每个可能特征及其阈值;

步骤2 对每个子集中的观测值进行相同的预测,预测值等于训练集上各样本的算数平均数;

步骤3 分别计算预测值和真实值之间的平方误差,将其作为损失函数值,根据损失函数值最小的特征值和阈值,将训练数据集划分为子集;

步骤4 递归执行上述步骤,通过选择最优特征值对训练集进行分割,形成单个决策树,输出包含每个节点分裂的特征值和阈值的组合;

步骤5 根据逐次的预测分数迭代构建多个决策树,并以准确率为权重,累加形成最终预测结果。

XGBoost算法通过汇总所有基学习器的结果来获取比单个模型更好的回归表现,降低模型偏差。XGBoost算法的目标函数对损失函数进行二阶泰勒展开,预测精度更高,且其目标函数纳入了正则项,能防止发生过拟合。此外,XGBoost算法会在训练前对特征进行排序,提升模型计算速度。XGBoost算法具有高效、灵活等特点,使其在数据挖掘等领域获得了广泛应用<sup>[11]</sup>。

考虑到大型活动客流数据集较大,而XGBoost算法能够在特征粒度上利用多线程并行提升模型的运行效率,减少运算时间,故本文采用XGBoost算法预测大型活动散场OD客流量。预测模型的输入为8类影响因素,预测模型的输出是散场时段以场馆附近车站为出发地、其他车站为目的地的OD客流量。采用绝对误差 $\Delta$ 和相对误差 $\delta$ 来衡量模型的预测效果,可以表示为:

$$\Delta = |P_{\text{pre}} - P_{\text{act}}| \quad (1)$$

$$\delta = (\Delta/P_{\text{act}}) \times 100\% \quad (2)$$

式中:

$P_{\text{pre}}$ ——客流预测值;

$P_{\text{act}}$ ——客流真实值。

根据历史数据分析,大型活动通常会诱发数千乘客在短时间内进站,将其分摊到线网各个车站的OD客流量数值可能并不大。为了合理有效地评价模型的预测效果,本文在OD层面仅关注超过10人次的OD,客流量小于10人次的OD具有较强的随机性,不参与OD层面的模型评价。此外,本文还采用在线路层面和进站量层面的绝对误差和相对误差作为预测模型的辅助评价指标。

在实际运输生产中,运营方通常会提前进行针



对大型活动的运力预安排,使运能与运量相匹配。为满足提前安排与及时调整运输计划的实际需求,本文提出基于数据时效性的滚动预测方案:在活动开始前一个月做运输计划时,将活动报备的起始车站、馆站距离、日期类型、活动类型、活动等级这5个特征数据作为模型的输入,进行第一次预测;在提前一周做运输计划调整时,获取天气数据再次进行预测;在活动开始后及时导出售票规模、出站人数数据加入预测模型中,进行第三次预测修正,并将该次预测修正结果作为运输计划的合理性验证或进一步调整运能的依据。

## 2.2 OD客流预测结果的个体进站时刻拟合

为了给车站工作人员提供精细的进站大客流预警,同时降低车站客流集聚事故风险,对OD客流预测结果进行个体进站时刻拟合,具体步骤为:

步骤1 确定大客流进站持续时长。对所有OD客流预测结果进行求和运算,得到起始车站的进站客流量,结合历史平均进站速率,即可得到大型活动散场客流的进站持续时长。

步骤2 生成个体进站时刻。假设乘客按照正态分布规律进站,根据 $3\sigma$ ( $\sigma$ 为标准差)原则,在每个时段区间内生成相应数量的大客流进站时刻,将其随机分配给进站个体,形成带有进站时刻的OD客流量数据。

步骤3 制定相应的车站客流管控策略。根据大客流分时进站情况,制定开关闸机、限流、站外排队等车站客流管控措施。

## 2.3 OD客流预测结果的精细化指标推算

大客流不仅会对本线路带来客运压力,还会通过换乘节点将其蔓延至整个线网。为了应对大客流风险,运营方需提前做好行车调整方案,以疏散激增客流,或进行乘客出行诱导,使其避开已拥堵的区段。

由于线网中的车站数量众多、单个OD客流量数量级较小等因素,运营方并不关注具体的OD客流量数值,而是关心线路区段的断面客流量及换乘节点的换乘客流量。因此,本文基于地铁公司普遍采用的清分模型算法,从乘客出行路径选择的角度,将OD客流预测结果换算为能为网络运营协同优化提供有效支撑的客流指标,具体步骤为:

步骤1 推算指标。基于带有个体进站时刻的OD客流量数据,结合列车运行图和客流路径清分比例表,推算大型活动散场大客流在各换乘站的换乘客流量、各趟列车的断面客流量及断面满载率。

步骤2 制定网络运营调整策略。根据散场客流途经各个通道、各趟列车的规模人数,结合不同区域的运能富余情况,制定增开列车、优化衔接、乘客路径诱导等网络运营调整策略。

## 3 案例验证分析

某车站附近场馆举办大型活动若干场次,部分活动结束后的散场进站客流量如图3所示。




图3 部分活动结束后的散场进站客流量

Fig. 3 Inbound passenger volume during the dispersal period after the end of some events

城市轨道交通AFC(自动售检票)系统和ACC(自动售检票清分中心)可以提供带时间的OD客流信息,网络资源可以提供影响因素信息。预处理后的模型输入数据中:起始车站用车站编号表示;日期类型用数字区分工作日或节假日;天气类型根据对出行的影响程度划分为不同等级,用数字表示;活动类型用数字区分不同性质的活动,如体育赛事、文艺表演等;活动等级按受欢迎程度划分为若干层次,用数字表示。预处理后的模型输入数据示例如表1所示。

所有数据按照8:2的比例划分训练集和测试集,XGBoost算法弱评估器的数量采用默认值100,大型活动散场OD客流预测结果如图4所示。由图4可知:XGBoost算法的预测值和真实值之间的差异性较小,能够灵敏地反映出不同目的地对客流吸引力的差异。

移动平均法、SVM(支持向量机)和XGBoost算法的预测效果对比,如表2所示。由表2可以知道:XGBoost算法的平均相对误差为15.1%,预测效果略好于SVM,移动平均法的预测效果最差。从线路

层面来看,客运量排名前四位的线路客运量相对误差分别为 2.7%、3.3%、3.1%、3.8%。从大型活动

诱发的进站客流量层面来看,预测值与实际值的相对误差为 2.11%。

表 1 预处理后的模型输入数据示例

Tab.1 Examples of pre-processed input data for the model


起始车站	馆站距离/ km	特征变量				标签变量			
		日期类型	天气类型	活动类型	活动等级	售票规模/张	出站人数/人	OD <sub>1</sub> 客流量/人次	OD <sub>2</sub> 客流量/人次
210	0.5	1	2	1	3	4 368	2 695	20	63
210	0.5	2	1	2	2	5 208	3 998	86	64

表 2 不同算法的预测效果对比

Tab.2 Comparison of prediction effects of different algorithms

OD 客流量/人次	OD 样本数/个	移动平均法		SVM		XGBoost 算法	
		$\Delta$	$\delta/\%$	$\Delta$	$\delta/\%$	$\Delta$	$\delta/\%$
>100	1	17	14.8	5	4.4	4	3.5
>40~100	1	12	13.6	4	4.6	1	1.1
>30~40	3	13	40.6	5	15.6	4	12.5
>20~30	2	16	69.6	7	30.7	6	26.1
>10~20	38	11	78.6	6	42.9	5	32.4

注:移动平均法的  $\delta$  均值为 43.4%;SVM 的  $\delta$  均值为 19.6%;XGBoost 算法的  $\delta$  均值为 15.1%。




注:OD 编号指标变量编号。

图 4 大型活动散场 OD 客流预测结果


Fig. 4 OD passenger flow prediction results during the dispersal after large-scale events

基于 OD 客流预测结果的个体进站时刻拟合方法及精细化指标推算方法,散场大客流的时空分布推演示意图如图 5 所示,其中:图 5 a)是按照 1 min 时间粒度根据正态分布将进站乘客分配到整个散场时段的推演示例,图 5 b)是根据乘客路径推算的沿途断面满载率和车站客运量推演示例。客运量较大的目的地车站和运能、运量冲突的区域并不完全重合,断面客流量、列车满载率和换乘客流量指标对于行车调整具有更大的参考价值。本线和关联线路均应进行运能、运量的适应性评估,及时做好应对大客流冲击的衔接优化、行车调度和乘客信息诱导等工作。此外,车站工作人员可根据图 5 中

的进站客流量峰值出现时刻及持续时长,评估闸机能力、站厅及站台客流滞留风险等,及时采取车站客流管控措施。



a) 大客流进站时间推演示例



b) 大客流空间转移推演示例

图 5 散场大客流的时空分布推演示意图

Fig. 5 Schematic diagram of the spatiotemporal distribution deduction of large passenger flows during the dispersal after large-scale events

## 4 结语

本文分析了大型活动诱发性城市轨道交通大客流的影响因素,提出了一种基于滚动数据驱动的XGBoost算法,预测了大型活动散场的OD客流量。所提算法模型在OD层面、线路层面、进站量层面取得了较好的预测精度,为车站客流管控和网络运营调整提供了决策依据,提高了预测数据在现场工作组织中的适应性和实用性。

此外,本文未提出具体且有针对性的车站客流管控措施和网络运营调整策略,这将是未来研究的重点方向。

## 参考文献

- [1] 梁强升. 大型活动期间地铁车站客流预测方法研究[J]. 城市轨道交通研究, 2021, 24(10): 196.  
LIANG Qiangsheng. Study on metro station passenger flow forecast during big events [J]. Urban Mass Transit, 2021, 24(10): 196.
- [2] 董春娇, 刘晓珂, 常乃心, 等. 基于网络搜索引擎的大型活动客流规模预测[J]. 北京交通大学学报, 2022, 46(4): 52.  
DONG Chunjiao, LIU Xiaoke, CHANG Naixin, et al. Passenger flow prediction for large-scale events based on network search engine [J]. Journal of Beijing Jiaotong University, 2022, 46(4): 52.
- [3] GUO Z, ZHAO X, CHEN Y, et al. Short-term passenger flow forecast of urban rail transit based on GPR and KRR[J]. IET Intelligent Transport Systems, 2019, 13(9): 1374.
- [4] ESSIEEN A, PETROUNIAS I, SAMPAIO P, et al. A deep-learning model for urban traffic flow prediction with traffic events mined from twitter[J]. World Wide Web, 2021, 24(4): 1345.
- [5] 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(5): 2042.  
YANG Jing, DAI Shengxu, ZHANG Hongliang, et al. Prediction of short-term passenger flow of metro station in the period of planned special events[J]. Science Technology and Engineering,

2021, 21(5): 2042.

- [6] JIN K, SUN S, LI H, et al. A novel multi-modal analysis model with Baidu Search Index for subway passenger flow forecasting [J]. Engineering Applications of Artificial Intelligence, 2022, 107: 104518.
- [7] LI W, SUI L, ZHOU M, et al. Short-term passenger flow forecast for urban rail transit based on multi-source data [J]. EURASIP Journal on Wireless Communications and Networking, 2021, 2021(1): 9.
- [8] 付宇, 翁剑成, 钱慧敏, 等. 基于XGBoost算法的大型活动期间轨道进出站量预测[J]. 武汉理工大学学报(交通科学与工程版), 2020, 44(5): 832.  
FU Yu, WENG Jiancheng, QIAN Huimin, et al. Prediction of metro passenger flow during large-scale activities based on XGBoost algorithm [J]. Journal of Wuhan University of Technology (Transportation Science & Engineering), 2020, 44(5): 832.
- [9] 郑云霄. 大型活动下城市轨道交通进出站客流短时预测研究[D]. 北京: 北京交通大学, 2019.  
ZHENG Yunxiao. Study on short-term prediction of passenger flow in and out of urban rail transit station under large-scale activities [D]. Beijing: Beijing Jiaotong University, 2019.
- [10] CHEN T, GUESTRIN C. XGBoost: a scalable tree boosting system [EB/OL]. (2016-03-09) [2023-03-11]. <https://arxiv.org/pdf/1603.02754v1>.
- [11] 门元昊, 吴亮, 刘晓双, 等. 基于XGBoost模型的地铁列车运行状态仿真方法[J]. 城市轨道交通研究, 2022, 25(3): 102.  
MEN Yuanhao, WU Liang, LIU Xiaoshuang, et al. A metro train running state simulation method based on XGBoost model [J]. Urban Mass Transit, 2022, 25(3): 102.

· 收稿日期:2023-04-05 修回日期:2023-05-10 出版日期:2025-05-10  
Received:2023-04-05 Revised:2023-05-10 Published:2025-05-10  
· 第一作者:周峰,高级工程师,zhoufeng24@tongji.edu.cn  
通信作者:王文昱,硕士研究生,24042113r@connect.polyu.hk  
· ©《城市轨道交通研究》杂志社,开放获取 CC BY-NC-ND 协议  
© Urban Mass Transit Magazine Press. This is an open access article under the CC BY-NC-ND license

(上接第23页)

- [7] PAN H, LI J, SHEN Q, et al. What determines rail transit passenger volume? Implications for transit oriented development planning[J]. Transportation Research Part D: Transport and Environment, 2017, 57: 52.

· 收稿日期:2024-10-23 修回日期:2024-12-18 出版日期:2025-05-10

Received:2024-10-23 Revised:2024-12-18 Published:2025-05-10

· 第一作者:郭英杰,博士研究生,guoyingjie@tongji.edu.cn  
通信作者:陈小鸿,教授,tongjicxh@163.com  
· ©《城市轨道交通研究》杂志社,开放获取 CC BY-NC-ND 协议  
© Urban Mass Transit Magazine Press. This is an open access article under the CC BY-NC-ND license