

引用格式:孙世超,宋新蕊.基于时空莫兰指数的轨道交通多类型异常客流特征分析[J].大连海事大学学报,2026,52(3):1-12.

基于时空莫兰指数的轨道交通多类型异常客流特征分析

孙世超*,宋新蕊

(大连海事大学 交通运输工程学院,辽宁 大连 116026)

摘要:异常客流是城市轨道交通运营安全面临的重要挑战,深刻把握其时空演化规律,是实现精准预警与高效响应的基础。然而,现有研究仍缺乏针对不同类型事件下异常客流特征的系统性对比分析。为此,本文以沈阳轨道交通网络为研究对象,构建基于客流波动的时空莫兰指数模型,对大型活动、节假日与恶劣天气三类事件引发的异常客流时空特征进行刻画分析。研究发现,三类异常客流均表现出时空正相关性,但演化模式具有显著差异:大型活动客流呈现“局部聚集、阶段突出”的非扩散性特征,时空冲击强、影响范围集中;节假日客流则具有“范围广、历时长”的多中心扩散特征,其演化主要源于站点功能替代,而非单纯需求增长;恶劣天气通过强化刚性通勤、抑制弹性出行,进一步推动客流向通勤骨干站点集聚;在复合事件情景下,客流结构呈现主导事件与背景事件相互叠加、协同作用的复合格局。本研究结论可为不同类型异常客流下的差异化运营管控与动态运力调度提供决策支持,并在特征构建与数据增强层面,为破解异常客流预测中“样本稀缺、难以学习”的瓶颈提供理论依据。

关键词:轨道交通;异常客流;时空特征;莫兰指数

中图分类号:U293.1

文献标志码:A

文章编号:1006-7736(2026)03-0001-12

doi:10.16411/j.cnki.issn1006-7736.2026.03.001

Analysis of multi-type abnormal passenger flow in urban rail transit based on spatiotemporal Moran's I

Sun Shichao*, Song Xinrui

(College of Transportation Engineering,

Dalian Maritime University, Dalian 116026, China)

Abstract: Abnormal passenger flow poses a significant challenge to the operational safety of urban rail transit. Accurate early warning and effective response depend on a deep understanding of the spatiotemporal patterns of such flows. However, existing studies still lack a systematic comparative analysis of the characteristics of abnormal passenger flow under different types of events. To address this gap, this study took the Shenyang rail transit network as the research object and constructed a spatiotemporal Moran's I model based on passenger flow fluctuations to compare and analyze the spatiotemporal evolution characteristics of abnormal passenger flows under three types of events: large-scale activities, holidays, and severe weather. The findings reveal that all three types of abnormal passenger flows exhibit significant spatiotemporal positive correlations, yet their evolution patterns differ markedly: large-scale activity passenger flows show a non-diffusive characteristic of “localized aggregation with strong periodicity”, featuring high spatiotemporal impact intensity but limited spatial scope; holiday passenger flows demonstrate a multi-center diffusion pattern with “wide influence range and long duration”, driven primarily by the functional substitution of stations rather than mere demand increase; severe weather intensifies rigid commuting demand while suppressing flexible travel, leading to further concentration of passenger flow at key commuting stations. Under composite event scenarios, passenger flow structures present a composite pattern resulting from the synergistic interaction between dominant and background events. The findings of this study can provide a decision-making basis for differentiated operational management and scheduling strategies under different types of abnormal passenger

收稿日期:2025-12-02;修回日期:2026-03-23

基金项目:国家自然科学基金资助项目(52302403);辽宁省社会科学规划基金项目(L24BGL005);中央高校基本科研业务费专项资金资助项目(3132026183)

作者简介:孙世超*(1988—),男,博士,副教授,博士生导师,E-mail:dlmu_sunshichao@163.com

flow events, while also offering theoretical support at the feature construction and data augmentation levels to address the bottleneck of “scarce samples and difficult learning” in abnormal passenger flow prediction.

Key words: rail transit; abnormal passenger flow; spatiotemporal characteristics; Moran's I

0 引言

随着城市轨道交通网络规模的持续扩大,地铁已成为承担居民日常通勤与出行的骨干交通方式。然而,在恶劣天气、大型活动等事件影响下,地铁客流常会在短时期内出现显著波动,形成与历史同期明显不同的“异常客流”^[1]。该类客流对运营组织与安全管理构成双重挑战,进而突显了开展高精度异常客流预测与预警研究的必要性。客流预测的本质在于精准捕捉其内在的时空动态特征与演化规律^[2]。反之,若模型未能有效刻画其复杂的时空依赖关系,即使预测模型结构复杂,也难以确保预测结果的准确性与可靠性^[3]。

客流是表征城市轨道交通系统运行状态的关键指标,其时空分布特征是轨道交通服务与土地利用共同影响的结果^[4]。现有研究利用丰富的交通大数据,从时空维度围绕客流分布特征展开研究^[5],但多以常规工作日客流为研究对象,针对特殊事件(如大型活动、恶劣天气)下的客流特征探讨相对较少。游世凯等^[6]在问卷调查数据基础上结合 AFC 数据,采用数理统计方法对无锡轨道交通客流特征进行分析。吴祥国等^[7]研究发现,客流的时空分布与站点性质、区位、周边用地类型及开发强度密切相关。叶倪碹等^[8]围绕工作日客流总量及时间特征展开研究,发现周五客流显著增加,并结合站点特征及出行行为分析周五新增客流的产生原因。郑俊锋等^[9]从客流结构、空间分布与时间变化角度,比较了大型活动前后地铁车站进出站客流的演变规律。Jiang 等^[10]以福州市为例进一步揭示高温、台风等极端天气对地铁网络、车站及 OD 层面总客流量的影响程度。Guo 等^[11]研究表明,恶劣天气会显著影响轨道交通客流。此时,乘客会更倾向于选择地铁或汽车出行。禹丹丹等^[12]基于北京地铁数据,从路网、线路及车站三个层面,提取客运量、进站量、断面流量等

指标,剖析节假日客流的时空特征及其成因。实际上,异常客流往往沿轨道交通网络结构扩散,并随时间动态演化^[13],其时空耦合特性要求分析方法具备更强的整合性。以上研究多采用时空分离的分析思路,难以充分揭示异常客流作为一种时空交互动态过程的本质特征。

在研究尺度方面,现有成果多集中于全网客流总量的宏观分析或局部站点、单一线路的微观探讨。钱慧敏等^[14]以北京园博会为例,从全网日客流量角度探讨大型活动对客流规模的影响,但未能反映网络内部不同站点之间的客流差异。Jiang 等^[15]通过分析上海与北京的地铁乘客总量,得到地铁乘客量随着疫情爆发急剧下降,而在控制新冠疫情后,地铁乘客量稳步增长的结果。Fernandes 等^[16]通过分析服务于两座体育场的三个车站的进出站客流数据,验证足球比赛对地铁客流的影响。Yao 等^[17]采用典型车站的客流数据来表征广州地铁节假日客流特征。肖逸影等^[18]选取客流量较大的断面与车站作为典型研究对象,对其在异常天气条件下的客流变化规律进行分析。但上述研究缺乏从轨道交通网络整体视角对多类型异常客流的系统分析,对异常客流在规模、结构与动态演化上的认识仍不够全面,难以提炼异常客流的共性规律与类型差异,进而制约了相关预测模型与管理策略的进一步优化。

为弥补上述研究不足,本文以沈阳市轨道交通网络为研究对象,聚焦大型活动、节假日与恶劣天气三类可预见的异常客流事件,在传统空间莫兰指数方法基础上引入时间维度,构建能够同步刻画时空关联特征的分析框架,系统比较不同异常客流的演化模式,从网络层面揭示异常客流的时空结构与演变规律,旨在为地铁运营部门实施差异化客流管控与动态运力调度提供决策依据,并为后续异常客流的数据增强与预测建模提供分析基础。

1 数据与方法

1.1 研究区域

本文以沈阳市轨道交通网络作为研究对象,研究区域以及地铁线路与站点的空间分布如图 1 所示。截至 2024 年 4 月,沈阳市已开通运营的地铁线路包括 1 号线、2 号线、4 号线、9 号线和 10 号

线,共计 111 座车站。




图 1 沈阳市地铁线路与站点分布示意图
Fig.1 Shenyang urban rail transit lines and station map

1.2 数据来源

本研究采用的数据主要包括以下四类。

(1)轨道交通客流数据。该数据来源于沈阳市轨道交通自动售检票系统(AFC),涵盖 2023 年 4 月至 2024 年 4 月期间的每日客流记录,包含线路名称、车站名称、进出站客流量、断面客流量等。

(2)大型活动信息。该信息通过“沈阳本地宝”“大麦网”等公共信息平台收集,内容包括活动名称、举办日期、举办场馆、开始时间等。

(3)气象数据。通过国家气象信息中心与 ERA5 平台,提取降雨量与降雪量数据。依据《中国气象等级标准》,将 24 h 累计降雪量 $\geq 5\text{ mm}$ 的天气界定为大雪及以上等级,将 24 h 累计降雨量 $\geq 25\text{ mm}$ 的天气界定为大雨及以上等级。

(4)兴趣点(POI)数据。兴趣点数据指城市或地理空间中具有特定功能或意义的地理实体位置数据,通常用于标注餐厅、学校、公司等具体地点。为分析不同时段客流变化与站点周边功能结构之间的关系,基于高德开放平台获取沈阳市轨道交通站点服务范围内的兴趣点数据,涵盖兴趣点类型、名称、经纬度与地址等信息,借助 ArcGIS 平台统计各站点服务区内不同类别的兴趣点数量。本文依据 POI 数据对应的城市用地功能特征,将其划分为 14 个类别,包括公司企业、购物消费、交通设施、科教文化、旅游景点、商务住宅、生活服务、休闲娱乐、餐饮美食等常见城市功能设施类型。

1.3 研究方法

1.3.1 异常客流识别与分类

异常客流指轨道交通站点客流量在短时间内显著偏离日常波动范围,并对运营组织产生影响的客流。常用的异常客流检测方法主要分为四类:基于统计、基于聚类、基于距离及基于密度的方法。其中,基于密度的方法适用于处理轨道交通站点分时客流多维数据,可有效捕捉局部与全局的离群数据点。局部离群因子(LOF)^[19]是基于密度的异常检测方法中的经典算法,其核心思想是在局部邻域范围内评估样本的相对密度水平,当某一对象的局部密度显著低于其邻域内其他对象时,该对象被视为偏离正常模式的“异常”数据。

本文基于 LOF 算法,对 2023 年 4 月至 2024 年 4 月共 365 天内各地铁站进站客流进行异常检测。结合事件信息、天气数据及轨道交通运营日志对检测结果进行校验与清洗,最终识别出 45 个存在实际客流异常的日期,并根据异常产生原因,将异常客流划分为三类可预见客流:大型活动型、节假日型与恶劣天气型。具体分类及说明见表 1。

表 1 异常客流类型及描述

Tab.1 Abnormal passenger flow types and descriptions

异常客流类型	具体描述
大型活动型	由体育赛事、演唱会等大型活动引发的客流异常。该类活动通常在特定时间与地点集中举办,导致短时间内客流急剧上升,属于“集中爆发型”客流 ^[20]
节假日型	节假日期间,居民及来访游客的出行需求以休闲、探亲、旅游、购物等为主,形成持续性的客流高峰 ^[21]
恶劣天气型	恶劣天气(如降雪等)会导致地面交通受阻,促使部分居民改变出行方式,影响城市轨道交通客流

本文采用主成分分析(PCA)方法,对识别得到的 45 个异常日期的全网分时客流数据开展降维处理与可视化分析。如图 2 所示,三类异常客流在主成分空间呈现明显分区,类间重叠较少,类内样本集中,表明各类别在统计特征上具有良好的区分度与内部一致性,验证了该分类的科学性与有效性。




图 2 三类异常客流在主成分空间中的分布

Fig.2 Distribution of three types of abnormal passenger flow in principal component space

1.3.2 客流波动指数

为量化异常客流的波动幅度并实现类型间的可比性,本文构建了客流波动指数。该指数在传统偏移率^[22]基础上引入基准客流标准差,以反映日常波动背景,并加入基于基准客流的权重函数,以抑制低客流基数站点因个别乘客变化导致的噪声放大。具体计算步骤如下。

(1) 客流基准值

为消除日期类型的影响,选取与异常日期同一日期类型(周一至周四、周五、周六/日)的多个正常日客流数据,计算其均值并将其作为客流基准值。

$$\bar{X}_{d,i,t} = \frac{1}{k} \sum_{d=1}^k X_{d,i,t} \quad (1)$$

式中: $X_{d,i,t}$ 为第 d 个正常日站点 i 在时段 t 的进出站客流; $\bar{X}_{d,i,t}$ 为站点 i 在时段 t 的进出站客流基准值; k 为正常日天数。

(2) 基准客流标准差

$$\sigma_{i,t} = \sqrt{\frac{1}{k-1} \sum_{d=1}^k (X_{d,i,t} - \bar{X}_{d,i,t})^2} \quad (2)$$

式中: $\sigma_{i,t}$ 为无特殊事件发生时, 站点 i 在时段 t

的客流日常波动范围。

(3) 客流权重函数

引入基于基准客流的权重函数,并通过参数 l 与站点 i 在时段 t 的基准客流对不同规模站点进行加权。在确定参数 l 的过程中,对不同取值方案进行对比分析:当被抑制的客流阈值设置过大时,高客流站点的权重被过度削弱,通勤早晚高峰特征受到影响;当阈值设置过小时,低基数站点的波动仍被显著放大,未能有效抑制噪声。综合考虑实际业务经验与样本分布特征,本文最终将基准客流第 25 百分位(约 400 人次/时)对应的权重值设定为 0.5,进而确定参数 l 的取值。

$$f(\bar{X}_{i,t}) = 1 - \exp(-l\bar{X}_{i,t}) \quad (3)$$

$$1 - \exp(-l\bar{x}_{25}) = 0.5 \quad (4)$$

(4) 客流波动指数

以客流波动指数 ($Q_{i,t}^{anom}$) 表征客流波动程度,其表达式为:

$$Q_{i,t}^{anom} = \frac{X_{i,t}^{anom} - \bar{X}_{i,t}}{\sigma_{i,t}} f(\bar{X}_{i,t}) \quad (5)$$

式中: $X_{i,t}^{anom}$ 为异常日站点 i 在 t 时间段内的进出站客流量; $Q_{i,t}^{anom}$ 为最终计算得到的异常情况下客流波动指数。 $Q_{i,t}^{anom} > 0$, 表示客流正向增长; $Q_{i,t}^{anom} < 0$, 表示客流负向下降; $|Q_{i,t}^{anom}|$ 越大,说明客流波动程度越大。

1.3.3 时空自相关分析

(1) 时空莫兰指数理论基础

改进的时空 Moran's I^[23] 在传统自相关分析中引入时间维度,用于评估客流波动在时空上的关联性。该指数涵盖全局与局部两类指标:全局指标用于衡量研究区域内客流波动的整体时空相关性,局部指标则用于识别局部区域中存在的聚集或异质模式。

全局时空 Moran's I 的数学表达式如下:

$$I_{global} = \frac{N \times T \times \sum_{p=0}^N \sum_{m=0}^T \sum_{q=0}^N \sum_{n=0}^T \mathbf{w}_{(p,m)(q,n)} (Q_{(p,m)} - \bar{Q})(Q_{(q,n)} - \bar{Q})}{\sum_{p=0}^N \sum_{m=0}^T (Q_{(p,m)} - \bar{Q})^2 \sum_{p=0}^N \sum_{m=0}^T \sum_{q=0}^N \sum_{n=0}^T \mathbf{w}_{(p,m)(q,n)}} \quad (6)$$

式中: N 为轨道交通网络中的站点总数; T 为研究

时段总数; $\mathbf{w}_{(p,m)(q,n)}$ 为时空邻接矩阵,表示站点 p

在时段 m 与站点 q 在时段 n 的邻接关系; $Q_{(p,m)}$ 为站点 p 在时段 m 的客流波动指数; $\bar{Q}$ 为时空单元客流波动指数的平均值,其计算公式为:

$$\bar{Q} = \frac{1}{N \times T} \sum_{p=0}^N \sum_{m=0}^T Q_{(p,m)} \quad (7)$$

全局时空 Moran's I 取值范围为 $[-1, 1]$ 。 $1 > I_{global} > 0$, 表示时空单元的属性值呈正相关,即高值与高值相邻、低值与低值相邻,且越接近 1,正相关性越强; $-1 < I_{global} < 0$ 则表示属性值呈负相关,即高值与低值相邻,越接近 -1,负相关性越强; $I_{global} = 0$ 表示时空单元之间呈随机分布。

定义 $I_{(p,m)}$ 为站点 p 在时段 m 的局部时空 Moran's I,其数学表达式如下:

$$I_{(p,m)} = Z_{(p,m)} \sum_{q=0}^N \sum_{n=0}^T w_{(p,m)(q,n)} Z_{(q,n)} \quad (8)$$

$$Z_{(p,m)} = \frac{(Q_{(p,m)} - \bar{Q})}{\sigma} \quad (9)$$

$$\sigma = \sqrt{\frac{\sum_{p=0}^N \sum_{m=0}^T (Q_{(p,m)} - \bar{Q})^2}{N \times T - 1}} \quad (10)$$

$I_{(p,m)} > 0$, 表示站点 p 在时段 m 的客流波动程度与其相邻时空站点的客流波动程度呈正相关; $I_{(p,m)} < 0$, 则二者呈负相关关系; $|I_{(p,m)}|$ 越大,表示时空相关性越强。

(2) 模型构建

本文以“站点-时段”为时空单元。其中, p 为轨道交通站点 ($p = 1, 2, \dots, N$), m 为研究时段 ($m = 1, 2, \dots, T$)。每个时空单元 $ST_{(p,m)}$ 的属性值为由式(5)计算得到的客流波动指数。

轨道交通客流具有沿网络传播的时空交互特征,即某一站点的客流状态不仅与当前时段相邻站点的状态相关,还与其前后相邻时段的客流状态密切相关。因此,本文通过空间邻接性与时间邻接性的交集构建时空权重矩阵 $w_{(p,m)(q,n)}$ 。具体地,当且仅当站点 p 与 q 空间邻接且时段 m 与 n 时间邻接时, $ST_{(p,m)}$ 与 $ST_{(q,n)}$ 为时空邻居, $w_{(p,m)(q,n)} = 1$, 否则为 0。

$$w_{(p,m)(q,n)} = \begin{cases} 1, & w(p,q) = 0, |m-n|=1 \\ 0, & \end{cases} \quad (11)$$

基于上述定义的时空单元与权重矩阵,分别计算全局与局部 Moran's I。为检验计算所得 Moran's I 的统计显著性,本文采用随机置换检验,重复次数 $r=999$ 。具体过程如下:随机打乱时空矩阵的属性值完成第 r 次样本置换,计算该次置换对应的 Moran's I 指数,进而求解得到显著性 P 值,具体数学表达式如下:

$$P = \frac{\sum_{r=1}^R (|I^r| \geq |I|) + 1}{R + 1} \quad (12)$$

式中:若 $|I^r| \geq |I|$ 条件成立,则其值为 1,否则为 0; $P < 0.05$, 即可拒绝原假设 H_0 : 数据在时空上随机分布,则有充分理由认为该研究单元具有显著的时空相关性。

(3) 结果可视化

为直观反映局部 Moran's I,本文采用莫兰散点图对其进行可视化。莫兰散点图的横轴为时空单元的标准化属性值 $Z_{(p,m)}$, 纵轴为其相邻时空单元标准化属性值的加权平均值。散点图将平面划分为四个象限,如图 3 所示。




图3 局部莫兰指数结果的四象限图

Fig.3 Four-quadrant scatter plot of local Moran's I

每个象限对应不同的时空聚集模式。

第一象限 (HH): 高值-高值聚集, 表示该站点在该时刻的客流波动较大, 且其相邻站点在相邻时刻的客流波动也较大, 说明这些站点在客流变化中表现出同步剧烈波动的聚集特征。

第二象限 (LH): 低值-高值聚集, 表示该站点在该时刻的客流波动较小, 但其相邻站点在相邻时刻的客流波动较大, 说明该站点对周边客流变化的响应较慢或受影响较弱。

第三象限 (LL): 低值-低值聚集, 表示该站点

与其相邻站点在相邻时刻的客流波动均较小,属于低客流波动聚集区。

第四象限(HL):高值-低值聚集,表示该站点在该时刻的客流波动较大,但其相邻站点在相邻时刻的客流波动较小,说明该站点可能出现孤立的客流波动,与周边站点不同步。

通过莫兰散点图,可直观识别出轨道交通网络中不同站点在不同时段的客流波动时空关联模式,为异常客流时空演化特征分析提供支持。

2 结果分析

选取大型活动(2023年7月29日某演唱会)、节假日(2023年五一小长假)与恶劣天气(2023年12月15日暴雪)三类典型场景,基于客流波动指数开展时空自相关分析。

2.1 常规与异常客流波动指数对比分析

将无特殊事件发生的普通工作日与休息日作为常规客流情景,与大型活动、节假日及恶劣天气三类特殊事件情景下的客流波动指数进行对比分析,重点刻画异常客流的波动强度特征。客流波动指数分布箱线图如图4所示。




图4 客流波动指数分布箱线图

Fig.4 Box plot of the distribution of passenger flow fluctuation index

由图4可知,特殊事件情景下异常客流的波动指数整体分布水平明显高于常规工作日与休息日,且离散程度显著增加。常规情景下,工作日与休息日的波动指数 $Q = -1.5 \sim 1.5$,中位数接近于0,未出现极端离群点,客流仅表现出轻微的自然波动。相比之下,三类异常客流的 Q 值均呈现明显的长尾分布特征。其中,节假日与暴雪天气情

景下的最大波动值分别达到30和25以上,大型活动情景下离群点数量较少,但其最大波动值接近50,个别站点出现了极端客流波动现象。

上述对比结果表明,异常客流冲击强度远高于常规客流自然波动,量级通常达到常规波动的20~40倍,直观地反映出异常客流并非简单的客流增加,而是对系统承载能力的巨大挑战。

2.2 全局时空莫兰指数分析

以客流波动指数为属性值,计算不同情景下的全局时空Moran's I,具体结果见表2。

表2 不同情景下的客流波动全局时空莫兰指数
Tab.2 Global spatiotemporal Moran's I for passenger flow fluctuation under different scenarios

类型	Moran's I	Z-score	P-value
大型活动	0.241	17.754	0.001
节假日	0.434	28.572	0.001
恶劣天气	0.430	31.453	0.001
常规工作日	0.307	22.854	0.001
常规休息日	0.282	18.887	0.001

由表2可知,所有情景下的全局时空Moran's I均为正值,且均通过1%的显著性水平检验,说明客流波动在时空维度上存在显著的正向自相关关系。具体地,在客流波动较大的站点,其相邻站点在相邻时段也倾向于出现较大波动,呈现“高-高”聚集的时空依赖特征。从Moran's I数值来看,节假日(0.434)与恶劣天气(0.430)的指数显著高于大型活动(0.241)与常规日(0.307, 0.282),反映出前两类事件对轨道交通全网客流的影响更为广泛,均引发更强的全局性时空联动效应;而在大型活动情景下,尽管个别站点客流波动强度最为剧烈,但其全局Moran's I不仅低于其他异常情景,甚至低于常规日,这表明大型活动对客流影响相对局部,主要集中在活动场馆周边区域,进而拉低了全局的时空聚集程度。

2.3 局部时空莫兰指数分析

2.3.1 局部时空莫兰指数结果分析

为深入识别异常客流在局部区域的聚集模式,计算三类事件下的局部时空Moran's I,并绘制热力图进行可视化分析,具体结果如图5—图7所示。




图 5 大型活动情景下局部时空莫兰指数热力图

Fig.5 Local spatiotemporal Moran's I heat map under large-scale events




图 6 节假日情景下局部时空莫兰指数热力图

Fig.6 Local spatiotemporal Moran's I heat map under public holiday events




图 7 恶劣天气情景下局部时空莫兰指数热力图

Fig.7 Local spatiotemporal Moran's I heat map under severe weather events

从局部聚集强度来看,大型活动与节假日均表现出显著的局部极端聚集现象,其核心热点区域与邻近站点之间的空间正相关性明显高于恶劣天气情景。结合全局 Moran's I 结果可知,大型活动虽对全网影响范围有限,但在局部站点可引发高强度客流波动;节假日则兼具较高的全局自相关性与局部极端性,其影响在空间上更为广泛且部分集中;相比之下,恶劣天气虽波及站点数量多,但局部聚集强度相对较弱、客流波动幅度较小。

在时空分布方面,三类事件影响下的异常客流特征呈现明显差异。

(1) 如图 5 所示,大型活动影响下的客流具有明显的阶段性性与集中性,客流波动主要出现在活动开始前(16:00—19:30)和结束后(22:30—24:00)两个时段,空间上高度集中于奥体中心站、天成街站等场馆邻近站点,反映出事件导向型客流的瞬时聚集与消散特征。以奥体中心站为例,其进出站客流变化如图 8 所示:常规休息日客流整体波动较小,未出现明显高峰;在举办大型活动的情景下,客流在常规休息日水平基础上形成新的峰值。其中,活动开始前的客流集聚导致出站客流出现明显高峰,而活动结束后的集中疏散则引发进站客流达到峰值。




图 8 大型活动下奥体中心站进出站客流

Fig.8 Passenger flow at Aotizhongxin station under large-scale events

(2) 如图 6 所示,节假日情景下,局部 Moran's I 的高值区在时空分布上更为广泛,覆盖全天大部分时段,符合节假日客流“平峰化”与持续活跃的特征,体现出休闲出行在时间上的延展性与空间上的扩散性。

值得注意的是,同一节假日在不同阶段的客流分布存在明显差异,如图 9 所示,整体呈现“节前逐渐增加—节中高位持续—节末逐步回落”的演化趋势。

(3) 如图 7 所示,恶劣天气情景下的高值区集中在早晚高峰时段,表现出强时间规律性。由于工作日的通勤需求是必须满足的刚性需求,因此,客流波动仍被约束在典型的通勤模式内。




图 9 节假日情景下不同阶段全网进出站客流

Fig.9 Passenger flow at all stations during different periods under public holiday events

2.3.2 莫兰散点图结果分析

莫兰散点图结果(表 3)显示,三类事件影响下的客流波动均呈现显著的时空聚集特征。由表 3 可知,高-高(HH)与低-低(LL)象限的单元占比远高于高-低(HL)与低-高(LH)象限,说明异常客流并非随机分布,而是以区域性同步增长或下降为主要特征,体现出明显的时空依赖性。

表 3 不同事件下各象限的莫兰散点占比

Tab.3 Proportion of stations in each Moran scatterplot quadrant across event types

类型	高-高 (HH) /%	低-高 (LH) /%	低-低 (LL) /%	高-低 (HL) /%
大型活动	3.856	1.046	4.510	0.392
节假日	7.516	0.261	3.856	0.654
恶劣天气	11.447	0.371	3.604	0.212
节假日+ 大型活动	3.987	0.719	8.824	1.046
降雨+ 大型活动	5.686	0.196	10.327	0.327

(1)大型活动情景下客流时空演变特征分析

大型活动情景下的客流波动表现出与活动进程高度同步的时空迁移路径(图 10)。10:00—16:00 活动开始前,中街、东中街等商业区站点持续呈现 LL 聚集,说明常规商业客流因活动吸引而减少;活动入场阶段(16:00—19:00),HH 站点数量显著上升,形成以奥体中心—天成街为核心的客流波动热点区;活动进行期间(19:30—

22:00),HH 聚集强度有所下降,而辽宁大学、沈阳航空航天大学等高校区出现 LL 聚集,反映出活动对学生出行行为产生了显著的吸附效应;活动结束后(22:00—24:00),HH 站点数量再次达到峰值,并以场馆为中心向外扩散,波及周边 1~3 个站点,形成了显著的连片化 HH 分布格局,同时,高校区也由不显著(NS)转为 HH 聚集,散场客流集中离场引发强波动。整体上,大型活动的客流波动具有明显的“入场—持续—散场”三阶段特征,其中,奥体中心—天成街片区为波动核心,周边站点承担客流集散与空间缓冲的关键作用。




图 10 大型活动情景下莫兰散点图 HH 象限与 LL 象限分布

Fig.10 HH and LL quadrants of the Moran scatterplot under large-scale events

(2)节假日情景下客流时空演变特征分析

节假日期间,客流波动表现出明显的时空扩散特征,显著聚类单元比例为 11.372%(HH+LL),高于大型活动(8.366%),反映了节假日客流在时空分布上的强关联性。

从时间演变来看,如图 11 所示,清晨 5:00—8:00 时段,沈阳站、沈阳北站等交通枢纽率先呈现高-低聚集特征,响应节假日早间旅客集中抵离的需求。日间 9:00—19:00 时段,高-高聚集区范围迅速扩展,形成以沈阳站、中街和重型文化广场为核心的三大热点区域。POI 数据表明,中街与重型文化广场周边站点的购物与餐饮类兴趣点数量合计占比均超过 40%,凸显商业休闲功能对客流聚集的主导作用。与此同时,沈阳站作为交通枢纽,持续吸引旅游客流,进一步强化其热点地位。夜间 19:00—23:00 时段,高-高聚集单元数量再次上升,中街、太原街等商业区及周围站点形成沿 1 号线的连续高值带,并通过青年大街换乘站向 2 号线扩散,影响范围延伸至金融中心、青年公园等站点,表现出典型的跨线传播效应。同时,

沈阳站与沈阳北站也再次呈现高-高聚集,反映出返程客流的集中涌入。值得关注的是,傍晚 16:00—19:00 时段,高校区域(如沈阳师范大学、沈阳航空航天大学、辽宁大学等)出现明显的低-低聚集,反映出学生与居民群体在节假日外出消费或返乡,导致本地客流下降,形成由功能单一区域向商业核心区迁移的客流重新分布现象。

综上,节假日客流整体呈现“枢纽先行—商业主导—夜间延续—返程客流”的典型扩散模式,具有空间范围广、持续时间长、功能导向鲜明的特征。




图 11 节假日情景下莫兰散点图 HH 象限与 LL 象限分布

Fig.11 HH and LL quadrants of the Moran scatterplot under public-holiday events

(3)恶劣天气情景下客流时空演变特征分析
恶劣天气情景下,HH 聚集单元的占比在三类事件中达到最高,为 11.447%,反映出该场景下全网客流拥有较强的同步波动特征。

如图 12 所示,早高峰期间,约 60% 的站点(如保工街、青年大街、医学院等)呈现显著 HH 聚集,这些站点多位于居住区或就业中心。这说明在暴雪等恶劣天气下,地面交通受阻促使更多通勤者转向轨道交通出行,加剧了刚性通勤需求对客流分布的集中影响。上午中后期(09:00—16:00),HH 聚集效应显著减弱,多数站点转为统计不显著或 LL 聚集状态,如中街、东中街等商业区及辽宁大学、沈阳航空航天大学等高校区,表明非刚性出行需求在恶劣天气下受到明显抑制。晚高峰时段,HH 聚集再次出现,说明下班通勤仍对轨道交通系统形成压力,但聚集规模与强度均低于早高峰。

早高峰聚集强度显著高于晚高峰,主要源于通勤行为的时空约束差异。早高峰出行以上班、上学等刚性需求为主,出发时间严格,即使天气恶

劣,出行者仍集中在规定时段完成通勤,导致客流高度聚集。晚高峰则因下班时间具有一定弹性,出行者可选择推迟离岗、调整行程或在室内滞留,从而分散了客流压力,降低了聚集程度。




图 12 恶劣天气情景下莫兰散点图 HH 象限与 LL 象限分布

Fig.12 HH and LL quadrants of the Moran scatterplot under severe weather events

(4)复合事件情景下客流时空演变特征分析
在沈阳轨道交通实际运营中,多类型事件叠加的情况时有发生。受限于现有数据,本文仅选取“节假日+大型活动”与“天气+大型活动”两类典型情况进行补充对比分析。

以 2023 年端午节假期辽宁体育馆梁静茹演唱会和降雨情况下的辽宁体育馆体育赛事为例进行研究分析。需说明的是,该复合事件的客流强度整体低于长假型节假日及超大型演唱会,但其时空演化特征仍具有较强代表性。

如图 13 所示,在日间时段(10:00—16:00),客流时空分布主要由节假日返程特征主导。与“五一”假期商业区站点呈现 HH 聚集不同,端午节假期末日多数商业类站点呈现 LL 或不显著(NS)聚集,而沈阳站、沈阳北站等综合交通枢纽周边形成明显的 HH 集聚区。这一空间分布特征反映了短假期尾声阶段市民购物休闲出行需求减弱、跨城返程需求集中的出行结构特征。在晚间时段(21:00—23:00),随着演唱会结束,活动场馆邻近站点奥体中心站由 NS 状态跃迁为 HH 聚集,其相邻的五里河站与营盘街站同步转为 HH 聚集,同样形成以场馆为核心的局部高值集聚区。

结合表 3 数据,在“节假日+大型活动”情景下,HH 象限站点占比(3.987%)与单一大型活动场景相近,而 LL 象限站点占比显著上升至 8.824%。该结果表明,在节假日高背景客流条件下,大型活动并未进一步扩大高值聚集范围。




图 13 “节假日+大型活动”情景下莫兰散点图
HH 象限与 LL 象限分布

Fig.13 HH and LL quadrants of the Moran scatterplot under “public-holiday events + large-scale events”

此外,在“降雨+大型活动”复合事件情景下,其局部时空莫兰指数结果与单一大型活动情景具有较高一致性,客流时空分布仍保持以大型活动为主导的演化特征,如图 14 所示。这是由于大型活动具有门票预付费、时间刚性强等特征,参与者出行决策对一般强度降雨(如降雨量 $<10\text{ mm}$)的敏感性较低,因此,案例中的降雨因素未显著改变既定的出行行为,场馆周边站点在入场与散场阶段仍呈现高强度时空集聚。但 LL 象限站点占比进一步升高至 10.327%,为所有情景中最高值,降雨天气显著降低了地铁网络中非刚性出行需求。




图 14 “降雨+大型活动”情景下局部
时空莫兰指数热力图

Fig.14 Local spatiotemporal Moran's I heat map under “rainfall + large-scale events”

综上,相比单一事件情景,复合事件情景下的客流波动仍具有二者的时空特征,但复合事件情景下的异常客流并非简单线性叠加,而是表现为全网节假日出行背景与局部活动事件驱动客流增量的叠加共存,其客流特征取决于两类事件作用强度及主导程度的相对关系,呈现为当前时段主导事件与背景事件共同作用的复合结构。

3 结论与启示

3.1 结论

本文基于改进的时空莫兰指数模型,以沈阳轨道交通为研究对象,融合 AFC 数据、事件信息与 POI 数据,从系统层面解析大型活动、节假日和恶劣天气三类事件下异常客流的时空演化规律。主要结论如下:

(1) 不同类型事件引发的客流异常,在波动强度、影响范围与网络关联性上存在显著差异

大型活动客流波动剧烈,但时空影响集中,主要局限于场馆周边 1~3 站范围内,并严格遵循“入场—停留—散场”的三阶段模式。节假日客流则表现出沿“交通枢纽—商业中心—夜间区域—返程枢纽”路径的定向扩散特征,形成跨线路传播结构,其本质是出行需求在空间上的功能替代与重新分布。在恶劣天气下,客流空间结构保持稳定,但通勤需求高度集中,使得早晚高峰时段的通勤站点呈现强关联聚集。此外,在复合事件(如降雨叠加大型活动)情景下,异常客流并非简单叠加,而是呈现“主导事件形成核心、背景事件调节范围”的复合格局,其分布受事件在特定时段相对主导性的影响。

(2) 异常客流的时空特征与站点功能属性紧密相关

大型活动对周边商业、高校区的常规出行产生替代效应;节假日客流波动主要由商业休闲类 POI 主导;恶劣天气下,网络功能向“通勤主导”收缩,通勤站点聚集增强,而非刚性出行站点(如商业、高校区)则转为低值聚集。

3.2 应用启示

基于上述特征结论,本文从预测建模与运营组织两方面提出以下应用建议,以提升异常客流的管理水平。

(1) 支持构建“特征驱动、事件导向”的异常客流预测方法

为破解异常客流样本稀缺难题、提升预测精度,可依托本文提取的差异化时空影响特征,实施事件驱动的异常客流预测建模。具体而言,针对“局部突发”的大型活动客流,宜采用场馆周边站点的短时精细化预测模型;针对“全网扩散”的节假日与恶劣天气客流,则需构建面向全网络的协

同预测模型。

此外,在特征工程方面,可将时空莫兰指数及其所揭示的关联模式作为关键输入特征,以增强模型对客流时空状态的动态辨识能力;同时,融合POI数据、事件属性等多源信息,进一步刻画不同功能站点对事件的响应差异。

针对异常客流样本不足的问题,可依据本文总结的莫兰指数区间、时空扰动范围等特征规则,开展有监督的数据增强,生成符合真实分布规律的仿真样本。该方法可有效缓解因样本稀缺导致的学习偏差,提升模型在罕见事件中的泛化性能与预测稳健性。

(2) 支持实施分类响应的运营组织策略

根据不同类型异常客流的时空演化特征,采取对应的差异化运营调度与客流管控措施。大型活动期间,应重点加强活动开始前与结束后场馆、核心站点的客流组织,并在1~3站距离范围内的外围站点预置疏散运力,以应对客流的瞬间聚集与短距离扩散。同时,应关注高校区与商业区站点在活动开始前可能出现的客流抑制现象,避免运力配置失衡。节假日情景下,轨道交通运营管控的重点应放在换乘枢纽与商业核心区站点的协同管控上,尤其要关注夜间时段客流沿换乘节点跨线传播引发的拥堵风险。恶劣天气未改变客流空间结构,建议将运力资源集中投放于原早晚高峰的通勤骨干站点,并适当削减非核心出行需求功能的运力配置,以提升系统整体的运营效率。

参考文献(References):

- [1] Wang Haiyang, Li Longyuan, Pan Pingjun, et al. Online detection of abnormal passenger out-flow in urban metro system[J]. *Neurocomputing*, 2019, 359: 327-340.
- [2] 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(4):93-102.
Li Zhaofeng, Ni Shaoquan, Sun Keyang, et al. Urban rail transit short-term passenger flow prediction based on multi-feature fusion[J]. *Journal of Transportation Engineering and Information*, 2020, 18(4): 93-102. (in Chinese)
- [3] Jin Guangyin, Cui Yan, Zeng Liang, et al. Urban ride-hailing demand prediction with multiple spatio-temporal information fusion network[J]. *Transportation Research*

Part C: Emerging Technologies, 2020, 117: 102665.

- [4] Gan Zouxian, Feng Tao, Wu Yunteng, et al. Station-based average travel distance and its relationship with urban form and land use: an analysis of smart card data in Nanjing city, China[J]. *Transport Policy*, 2019, 79: 137-154.
- [5] Li Yuan, Yang Linchuan, Shen Han, et al. Modeling intra-destination travel behavior of tourists through spatio-temporal analysis[J]. *Journal of Destination Marketing & Management*, 2019, 11: 260-269.
- [6] 游世凯,张聪,邹歆.基于多源数据的无锡轨道交通客流特征分析[J].*都市快轨交通*,2020,33(5):94-100.
You Shikai, Zhang Cong, Zou Xin. Passenger flow characteristics of Wuxi urban railway based on multi-source data[J]. *Urban Rapid Rail Transit*, 2020, 33(5): 94-100. (in Chinese)
- [7] 吴祥国,翟长旭,张建嵩,等.重庆市郊铁路江跳线客流时空特征分析[J].*铁道运输与经济*,2024,46(5):192-200.
Wu Xiangguo, Zhai Changxun, Zhang Jiansong, et al. Analysis of spatial-temporal characteristics of passenger flow in Chongqing suburban railway Jiangtiao line[J]. *Railway Transport and Economy*, 2024, 46(5): 192-200. (in Chinese)
- [8] 叶倪碹,杨超,闫茜.深圳市轨道交通周五大客流特征及成因分析[J].*城市轨道交通研究*,2021(5):24.
Ye Nixuan, Yang Chao, Yan Qian. Characteristics and cause analysis of Shenzhen rail transit large passenger flow on Friday[J]. *Urban Mass Transit*, 2021(5): 24. (in Chinese)
- [9] 郑俊锋,方旭峰,王晨阳.基于时间序列分解方法的城市轨道交通大客流预测方法[J].*城市轨道交通研究*,2023,26(8):163-170.
Zheng Junfeng, Fang Xufeng, Wang Chenyang. Prediction method for urban rail transit large passenger flow based on time series decomposition[J]. *Urban Mass Transit*, 2023, 26(8): 163-170. (in Chinese)
- [10] Jiang Shixiong, Lin Yuchen. Ridership and human mobility of metro system under the typhoon weather event: a case study in Fuzhou, China[J]. *Urban Rail Transit*, 2022, 8(1): 32-44.
- [11] Guo Yongqing, Wang Xiaoyuan, Xu Qing, et al. Weather impact on passenger flow of rail transit lines[J]. *Civil Engineering Journal*, 2020, 6(2): 276-284.
- [12] 禹丹丹,陈文,韩庆龙,等.北京地铁节假日客流特点和运营组织方法分析[J].*现代城市轨道交通*,2019

- (4):58-66.
- Yu Dandan, Chen Wen, Han Qinglong, et al. Analysis of Beijing subway passenger flow characteristics and operation organization method during holidays[J]. *Modern Urban Transit*, 2019(4): 58-66. (in Chinese)
- [13] 马飞, 蒋金凤, 敖誉芸, 等. 非均衡大客流冲击下城市轨道交通网络抗毁性建模及演化特征[J]. *清华大学学报(自然科学版)*, 2024, 64(10): 1717-1733.
- Ma Fei, Jiang Jinfeng, Ao Yuyun, et al. Modeling and evolution characteristics of urban rail transit network resistance under large passenger flows[J]. *Journal of Tsinghua University (Science and Technology)*, 2024, 64(10): 1717-1733. (in Chinese)
- [14] 钱慧敏, 李静, 张琳, 等. 持续型大型活动影响因素及客流分布特征分析[J]. *交通工程*, 2020, 20(1): 60-65.
- Qian Huimin, Li Jing, Zhang Lin, et al. Analysis of influence factors and passenger flow distribution characteristics about lasting large-scale events[J]. *Traffic Engineering*, 2020, 20(1): 60-65. (in Chinese)
- [15] Jiang Shixiong, Cai Canhuang. Unraveling the dynamic impacts of COVID-19 on metro ridership: an empirical analysis of Beijing and Shanghai, China[J]. *Transport Policy*, 2022, 127: 158-170.
- [16] Fernandes P, Santos L, Bandeira J M, et al. Multiple linear regression of metro ridership in the context of football events: a case study of Metro de Lisboa[J]. *Transportation Research Procedia*, 2025, 86:151-158.
- [17] Yao Enjian, Hong Junyi, Pan Long, et al. Forecasting passenger flow distribution on holidays for urban rail transit based on destination choice behavior analysis[J]. *Journal of Advanced Transportation*, 2021(1): 9922660.
- [18] 肖逸影, 王东, 吴宁宁, 等. 冻雨极端天气下武汉市轨道交通客流特征分析[J]. *现代城市轨道交通*, 2025(7):107-113.
- Xiao Yiyang, Wang Dong, Wu Ningning, et al. Analysis of passenger flow characteristics of Wuhan municipal rail transit under extreme weather condition of freezing rain[J]. *Modern Urban Transit*, 2025(7): 107-113. (in Chinese)
- [19] Alghushairy O, Alsini R, Soule T, et al. A review of local outlier factor algorithms for outlier detection in big data streams [J]. *Big Data and Cognitive Computing*, 2021, 5(1): 1.
- [20] 杨静, 代盛旭, 张红亮, 等. 大型活动散场期间地铁站短时进站客流预测[J]. *科学技术与工程*, 2021, 21(5):2042-2048.
- 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): 2042-2048. (in Chinese)
- [21] Liu Jianxiao, Shi Wenzhong, Chen Pengfei. Exploring travel patterns during the holiday season—a case study of Shenzhen metro system during the Chinese spring festival[J]. *ISPRS International Journal of Geo-Information*, 2020, 9(11): 651.
- [22] Kalkstein A J, Kuby M, Gerrity D, et al. An analysis of air mass effects on rail ridership in three US cities[J]. *Journal of Transport Geography*, 2009, 17(3): 198-207.
- [23] 陈绍宽, 韦伟, 毛保华, 等. 基于改进时空 Moran's I 指数的道路交通状态特征分析[J]. *物理学报*, 2013, 62(14):527-533.
- Chen Shaokuan, Wei Wei, Mao Baohua, et al. Characterization of road traffic state based on improved spatio-temporal Moran's I index [J]. *Acta Physica Sinica*, 2013, 62(14): 527-533. (in Chinese)