

doi: 10.3969/j.issn.1672-6073.2025.03.007

基于 GMM 模型的城市轨道交通 乘客通勤模式研究 ——以长沙市为例

邓洁榕¹, 刘晨辉^{1,2,3}

(1. 湖南大学土木工程学院, 长沙 410082; 2. 湖南大学综合交通研究中心, 长沙 410082;
3. 桥梁工程安全与韧性全国重点实验室(湖南大学), 长沙 410082)

摘要: 本研究旨在分析城市轨道交通乘客的通勤模式, 并探讨不同类型通勤乘客的特征及其规律。采用长沙市地铁 2023 年 3 月 21 日至 4 月 3 日两周工作日的 AFC 刷卡数据, 选取上班进站时间、下班进站时间、地铁通勤耗时 3 个指标, 构建高斯混合模型(Gaussian mixture model, GMM), 最终将乘客划分为三类: 经典通勤模式、长距离通勤模式、错峰通勤模式。研究结果表明: 从通勤时间来看, 经典通勤模式的通勤时间主要集中在常规高峰时段(7:30-8:30、17:30-18:30), 长距离通勤模式通勤时间则略有提前, 而错峰通勤的乘客则避开常规通勤高峰, 上班进站时间涵盖了 7:00 到 12:00 的整个时间段, 下班进站时间集中在 20:00-22:00; 从通勤耗时来看, 经典通勤模式和错峰通勤模式乘客的通勤时长主要分布在 15~30 min, 而长距离通勤模式的通勤时长多在 30 min 以上; 从居住、工作站点分布来看, 长距离通勤乘客的居住站点在市区外围的分布比例显著高于其他两类乘客, 错峰通勤乘客的工作站点比其他两类更为集中, 主要位于餐饮和娱乐行业聚集的商业区。

关键词: 城市轨道交通; 通勤客流; 出行特征; 高斯混合模型; 聚类分析; AFC 数据; 职住分布

中图分类号: U231

文献标志码: A

文章编号: 1672-6073(2025)03-0048-06

Exploration of Travel Patterns of Urban Rail Transit Commuters Based on Gaussian Mixture Model (GMM): A Case Study of Changsha, China

DENG Jierong¹, LIU Chenhui^{1,2,3}

(1. College of Civil Engineering, Hunan University, Changsha 410082;
2. Transportation Research Center, Hunan University, Changsha 410082;
3. National Key Laboratory of Bridge Safety and Resilience, Hunan University, Changsha 410082)

Abstract: This study analyzes commuting patterns in urban rail transit and investigates the characteristics and regularities of different commuter types. The analysis is based on Changsha Metro AFC data, covering two consecutive weeks of working days from March 21 to April 3, 2023. A Gaussian Mixture Model (GMM) is constructed using three variables: morning boarding time, evening boarding time, and the average commuting duration. This model classifies passengers into three categories: the classic commuting pattern, the off-peak commuting pattern, and the long-distance commuting pattern. The results show that classic

收稿日期: 2024-09-02 修回日期: 2024-12-18

第一作者: 邓洁榕, 女, 硕士研究生, 研究方向为轨道交通客流特征, jierong99@hnu.edu.cn

通信作者: 刘晨辉, 男, 博士, 教授, 从事公共交通运营、交通安全与应急等研究, chenhuiliu@hnu.edu.cn

基金项目: 湖南省自然资源厅科技计划项目(HBZ20240122)

引用格式: 邓洁榕, 刘晨辉. 基于 GMM 模型的城市轨道交通乘客通勤模式研究: 以长沙市为例[J]. 都市轨道交通, 2025, 38(3): 48-53.

DENG Jierong, LIU Chenhui. Exploration of travel patterns of urban rail transit commuters based on gaussian mixture model (GMM): a case study of Changsha, China[J]. Urban rapid rail transit, 2025, 38(3): 48-53.

commuters primarily commute during regular peak hours (7:30–8:30 and 17:30–18:30), while long-distance commuters tend to start slightly earlier, and off-peak commuters avoid peak periods, with their morning boarding times spanning from 7:00 to 12:00 and evening boarding times concentrated between 20:00 and 22:00. In terms of commuting duration, classic and off-peak commuters typically travel for 15 to 30 minutes, whereas long-distance commuters predominantly travel for over 30 minutes. Additionally, the residential and workplace station distributions highlight that long-distance commuters are more likely to reside in peripheral urban areas, and the workplace stations of off-peak commuters are more concentrated than those of the other two groups, predominantly located in areas bustling with dining and entertainment activities.

Keywords: urban rail transit; commuter; travel pattern; Gaussian mixture model; clustering analysis; AFC data; job-housing separation

0 引言

近年来,我国城市轨道交通发展迅速。截至 2023 年底,我国内地累计已有 59 座城市开通运营城市轨道交通线路,总里程 11 232.65 km,客运量 293.89 亿人次,均居全球首位^[1-2]。由于城市轨道交通投资规模大、建设周期长、运营成本高,其主要目标为服务通勤需求,因此深入研究城市轨道交通客流通勤模式,不仅有助于运营商持续优化轨道交通运营组织,提高运输效能和服务水平,从而吸引更多通勤客流,还能为合理规划设计新的城市轨道交通线路提供理论支撑与数据支持,推动城市轨道交通系统的可持续发展。

基于刷卡数据的公共交通乘客出行特征分析,国内已有一些研究。程小云等^[3]采用西安地铁 30 d 刷卡数据,利用 GMM 算法将乘客分为 5 类,并分析了不同群体的行为动力学特征;刘哲园等^[4]采用杭州地铁 5 个工作日刷卡数据,利用二阶段聚类法,首先对出行强度初始聚类,然后对时空特征再聚类,将乘客分为 8 类;倪汪凌等^[5]采用上海市地铁刷卡数据,从时间、空间和频次 3 个维度构建异常用户评价指标,用异常得分衡量乘客出行行为异常程度,利用 K-means 算法将异常出行乘客分成 5 类;姚志刚等^[6]采用浙江海宁市 2 个月的刷卡数据,联合重复性和周期性指标,利用 K-means 算法将公交乘客分为重复性强且周期性弱、重复性强但周期性弱、重复性弱且周期性弱 3 类;LIU 等^[7]则采用深圳地铁 3 周刷卡数据,对深圳市春节期间的地铁出行行为进行研究,采用 LDA(latent dirichlet allocation)模型,推断出 3 类 9 种出行模式。

现有研究多聚焦于特定时间段内对所有乘客的整体出行模式进行分类,而针对特定人群(如通勤乘客)进行精细化分析的研究相对较少。同时,研究重点往往关注客流的出行强度和um时间特征,对职住空间分布及其关联特征的探讨仍显不足。此外大部分研究使用的数据相对陈旧,难以全面反映当前乘客出行特征的动态变化。因此本研究基于长沙市地铁 2023 年 3 月

21 日至 4 月 3 日两周工作日的 AFC 刷卡数据,以通勤乘客为研究对象,深入挖掘其细分模式及差异化特征,并对其职住空间分布特征进行分析,为优化城市轨道交通系统运营、提高服务质量、满足乘客的多样化需求提供理论依据与技术支持。

1 数据概况与处理

长沙市是我国中部重要的中心城市,湖南省会,也是我国特大城市之一。截至 2023 年底,长沙市常住人口为 1 051.31 万人^[8],总面积 11 819 km²。自 2014 年开通首条地铁线路以来,长沙轨道交通网络逐渐完善。截至 2023 年 3 月底,长沙市已开通运营 6 条地铁线路,包括 1~6 号线,共设有 145 座车站,其中换乘站 18 座,线路总长 190.6 km,基本覆盖长沙市主要城区,图 1 展示了地铁线路分布,表 1 详细列出了各线路的开通时间、长度以及车站数量。

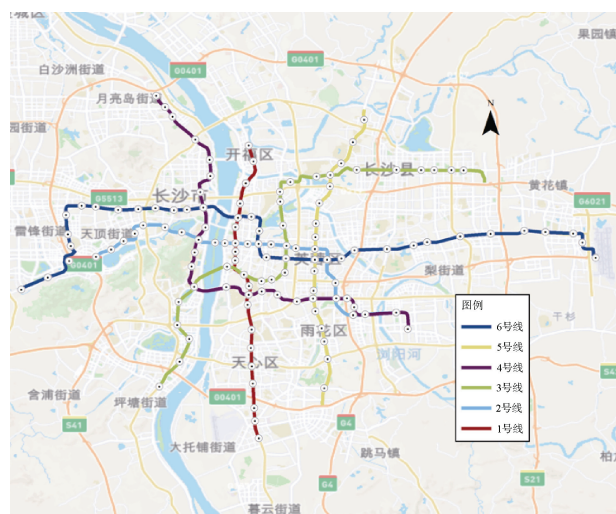


图 1 长沙市地铁线路

Figure 1 The map of Changsha Metro lines

为分析长沙地铁通勤客流特征,本研究采集了 2023 年 3 月 21 日至 4 月 3 日共计 2 周 10 个工作日的地铁 AFC 刷卡数据,数据示例如表 2 所示。

表 1 长沙市地铁线路概况(截至 2023 年 3 月)

Table 1 Overview of Changsha Metro lines (March 2023)

线路	开通时间	长度/km	车站数量/座
1	2016/6/28	23.63	20
2	2014/4/29	26.53	23
3	2020/6/28	36.40	25
4	2019/5/26	33.52	25
5	2020/6/28	22.42	18
6	2022/6/28	48.11	34

表 2 AFC 数据示例

Table 2 Example of electronic post-payment AFC data

卡号	进站时刻	进站 车站	进站 线路	出站 时刻	出站 车站	出站 线路
1004036621	2023/3/21 06:24	花桥	6	06:45	龙华	6
1005454527	2023/3/21 06:38	黄兴广场	1	06:50	文昌阁	1
...

作为知名旅游城市,长沙旅游客流量较大。因此,工作日地铁客流不仅包括通勤客流,还有大量以购物、观光为主的旅游客流,因此提取通勤客流是首要亟待解决的问题。对通勤客流的识别主要包括两类:一类建立 AFC 刷卡数据与家庭出行调查数据之间的数学模型^[9];另一类通过对家庭出行调查数据描述性统计分析总结通勤客流规律,进而提取通勤客流^[10]。由于缺少长沙市家庭出行调查数据,本研究借鉴其他研究对通勤客流规律的总结,进行通勤乘客的筛选。

Step1: 计算乘客出行天数,识别高频出行乘客。大多数研究将调查时间内出行天数大于某一阈值的乘客定义为高频出行乘客,但不同研究取值有所不同。例如,LIU 等^[7]将 21 d 内出行天数大于 6 d 的乘客定义为高频出行乘客,而 LIU 等^[11]则将 28 d 内出行天数大于 10 d 的乘客认定为高频出行乘客。参考现有研究,本文采用 K-means 算法根据出行天数将乘客分成两组进而确定阈值,最终将阈值设置为 6 d,即 10 d 内出行天数不少于 6 d 的乘客为高频出行乘客。

Step2: 计算每日出行时间,识别通勤乘客。考虑到通勤行为通常包括 1 次去程和 1 次返程,因此在本研究中单日出行记录有 2 条及以上的才被识别为通勤记录。此外,乘客在工作地点往往要停留数小时,有研究表明通勤者在工作地点往往停留 6 h 以上^[10],因此本文提取两次记录间隔时间 6 h 以上的记录。

经过筛选,最终识别出 129 233 名通勤乘客,共计 2 267 515 条出行记录。这些乘客周均工作日出行天数为 4.1 d,日均出行次数为 2.1 次。

针对每位通勤乘客,还需要进一步判定其上(下)

班进站时间以及居住(工作)站点,判定方式如下:

1) 上(下)班进站时间:认定其每天首次地铁出行为上班出行,而末次地铁出行为下班出行。提取调查期内其每天上(下)班出行的进站时间,计算其中位数作为该乘客的上(下)班进站时间。

2) 居住(工作)站点:提取其每天上班出行的进(出)站点,将调查期内出现频率最高的进(出)站点作为其居住(工作)站点。当出现多个频率相同的进(出)站点时,则计算这些站点与工作(居住)站点的距离,选择距离最远的站点为居住(工作)站点。

2 通勤乘客聚类分析

2.1 聚类指标选取

参考现有研究,筛选上班进站时间、下班进站时间、地铁耗时 3 个指标对乘客进行聚类分析(见表 3)。为了更好地进行数据处理、分析和模型构建,基于 24 小时制将时间统一转换为分钟进行计算(小时数×60+分钟数,例如 6:10 将被转化为 370)。

表 3 聚类选取指标

Table 3 Clustering indicators

指标	最小值	最大值	中位数	标准差
上班进站时间/min	370 (06:10)	995 (16:35)	492 (08:12)	-
下班进站时间/min	1 124 (18:44)	1 417 (23:37)	1 100 (18:20)	-
地铁通勤耗时/min	4	107	29	11.96

2.2 GMM 聚类算法

GMM(Gaussian mixture model)模型假设数据由 K 个高斯分布组合而成,每个高斯分布对应一个聚类,其概率密度函数计算方式如下:

$$P(X) = \sum_{k=1}^K \pi_k N(X|\mu_k, \Sigma_k) \quad (1)$$

$$N(X|\mu_k, \Sigma_k) = \frac{\exp\left(-\frac{1}{2}(X - \mu_k)^T \Sigma_k^{-1}(X - \mu_k)\right)}{(2\pi)^{d/2} |\Sigma_k|^{1/2}} \quad (2)$$

式中, X 为数据点(维度为 d 的向量); $P(X)$ 为数据点的概率密度函数; K 为高斯分布的总个数; π_k 为第 k 个高斯分布的权重; $N(X|\mu_k, \Sigma_k)$ 为第 k 个高斯分布的概率密度值; μ_k 为第 k 个高斯分布的均值向量; Σ_k 为第 k 个高斯分布的协方差矩阵。

GMM 模型通常使用期望最大化(expectation-maximization, EM)算法来求解,具体步骤如下:

1) E 步:使用当前模型,计算每个数据点 X_i 属于

每个高斯分布 k 的概率, 记做 $\gamma(Z_{ik})$:

$$\gamma(Z_{ik}) = \frac{\pi_k N(X_i | \mu_k, \Sigma_k)}{\sum_{k=1}^K \pi_k N(X_i | \mu_k, \Sigma_k)} \quad (3)$$

2) M 步: 根据 E 步计算出的 $\gamma(Z_{ik})$, 重新估计高斯分布的参数。

更新均值 μ_k :

$$\mu_k = \frac{\sum_{i=1}^N \gamma(Z_{ik}) X_i}{\sum_{i=1}^N \gamma(Z_{ik})} \quad (4)$$

更新协方差矩阵 Σ_k :

$$\Sigma_k = \frac{\sum_{i=1}^N \gamma(Z_{ik}) (X_i - \mu_k)(X_i - \mu_k)^T}{\sum_{i=1}^N \gamma(Z_{ik})} \quad (5)$$

更新 π_k :

$$\pi_k = \frac{\sum_{i=1}^N \gamma(Z_{ik})}{N} \quad (6)$$

在每次迭代中, 对数似然函数为:

$$\log P(X) = \sum_{i=1}^N \log \left(\sum_{k=1}^K \pi_k \cdot N(X_i | \mu_k, \Sigma_k) \right) \quad (7)$$

式中, X_i 为第 i 个数据点; $\gamma(Z_{ik})$ 为数据点 X_i 属于第 k 个高斯分布的后验概率; N 为样本数量。

重复 E 步和 M 步, 直到 $\log P(X)$ 收敛。

GMM 聚类算法利用多个正态分布组合刻画数据的复杂分布, 从而实现对本样本数据的聚类。考虑到不同乘客群体的出行模式可能具有不同的分布形状和密度, GMM 可以灵活适应这些分布的复杂性。此外, GMM 通过估计数据点属于每个簇的概率进行软聚类, 可以更好地捕捉乘客出行行为的模糊边界, 因此本研究采用 GMM 算法进行聚类。

3 结果分析

3.1 聚类中心

使用 GMM 模型对识别出来的 129 233 名通勤乘客进行聚类。由于 GMM 模型的聚类效果与高斯模型数量关系密切, 为了确定最佳聚类数, 本文采用贝叶斯信息准则(BIC)进行评估(见图 2)。可以发现, BIC 得分在聚类数量从 1 增加到 3 时下降幅度最大, 超过 3 后, 下降的幅度明显减小并趋于平缓, 因此根据肘部法则, 将乘客分为 3 类。各类乘客的指标如表 4 所示。

1) 第 1 类乘客占总样本的 48.9%, 其上班与下班进站时间中位数分别为 8:14 和 18:16, 与长沙市地铁早晚高峰^[12](7:30-8:30, 17:30-18:30)基本一致。因此, 将这一

类别命名为经典通勤模式, 其平均通勤耗时 24 min。




图 2 BIC 得分

Figure 2 BIC scores

表 4 通勤乘客聚类中心

Table 4 The center point for different clustering passengers

编号	乘客类别	上班进站时间中位数	下班进站时间中位数	平均地铁通勤耗时	比例
1	经典通勤	08:14	18:16	24	48.9%
2	错峰通勤	09:54	21:08	27	17.7%
3	长距离通勤	07:58	18:09	40	33.4%

2) 第 2 类乘客占总样本的 17.7%, 其上班和下班进站时间中位数分别为 9:54 和 21:08, 均避开了地铁早晚高峰时段。因此, 将这一类别命名为错峰通勤模式, 其平均通勤耗时 27 min, 与第 1 类乘客相近。

3) 第 3 类乘客占总样本的 33.4%, 其上班和下班进站时间中位数分别为 7:58 和 18:09, 分别比第 1 类乘客提早 16 min 和 7 min; 平均通勤耗时 40 min, 是第 1 类乘客的 1.67 倍。分析认为, 这类乘客居住地离工作地较远, 通勤距离较长, 出行较早, 耗时较长, 因此将其命名为长距离通勤模式。

图 3 展示了各类乘客上下班进站时间的概率密度分布。可以发现经典通勤模式与长距离通勤模式的分布曲线相似, 上班进站时间集中在 7:30-8:30, 下班进站时间集中在 17:30-18:30, 但长距离通勤模式的早晚高峰峰值比经典通勤模式略有提前。错峰通勤乘客的上班进站时间在各个时段分布较为均匀, 但下班进站时间则集中在 20:00-22:30, 说明这类乘客的工作结束时间较晚, 通常避开了晚高峰时段。

3.2 概率密度分布

图 4 展示了各类乘客平均通勤耗时的概率密度分布。可以发现, 经典通勤模式通勤耗时集中在 15-30 min, 峰值明显, 出现在 25 min; 错峰通勤模式通勤耗时分

布比较均匀,集中在 10-35 min,峰值出现在 20 min。由于长沙市平均通勤时间为 30 min,因此经典和错峰通勤乘客的通勤时长低于全市平均水平,表明其以中短距离通勤者为主。而长距离通勤乘客通勤耗时集中在 30-45 min,峰值为 35 min,大于全市平均水平。

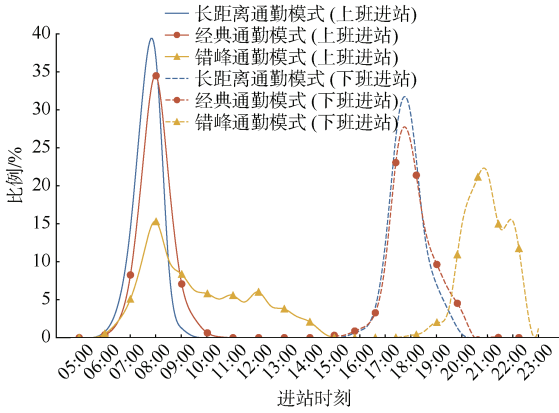


图 3 各类通勤客流上下班进站时间分布

Figure 3 The probability density distribution of boarding and alighting time by different commuter clusters




图 4 各类通勤客流地铁平均通勤耗时分布

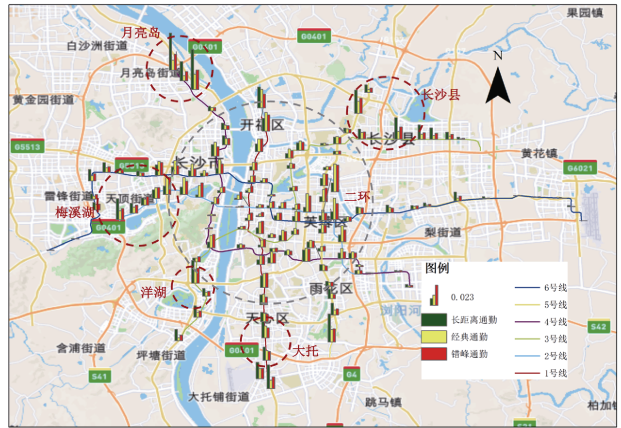
Figure 4 The probability density distribution of average commuting time by different commuter clusters

3.3 职住分布

3 类客流的居住和工作站点分布分别如图 5 所示。总的来说,长沙市工作岗位呈中心城区单核集中分布态势,而居住地则呈市区边缘多核分散态势,职住分离现象突出。具体来说:

1) 经典通勤乘客居住站点多集中在长沙市二环以内,且在中心城区的分布比例较另外两类更高。此外,其工作站点主要位于核心城区,但比较分散。总的来说,经典通勤乘客居住与工作站点均围绕在二环以内及周边区域。

2) 与经典通勤乘客相比,错峰通勤乘客居住站点分布类似,但工作岗位高度集中于五一广场(13.4%)、黄兴广场(4.4%)和芙蓉广场(3.6%)等少数地处长沙主要



(a) 居住站点



(b) 工作站点

图 5 各类通勤客流居住和工作站点分布

Figure 5 The probability density distribution of work and residential stations for different commuter clusters

商业圈的站点。以五一广场站为例,其地处长沙核心商业区,周边餐饮、旅游、购物、娱乐等服务业高度发达,而这些行业的营业时间通常更加灵活,且往往持续到更晚。因此可以推测,错峰通勤客流主要为这些服务行业的从业人员。

3) 与经典通勤客流相比,长距离通勤乘客多居住于长沙二环以外,且集中分布于月亮岛、大托、梅溪湖、洋湖、长沙县等区域。相比之下,其工作站点分布更加均匀,遍布整个市区。分析认为,月亮岛等区域多为近些年开发的城市新区,以住宅为主,工作岗位有限,这导致居民不得不长距离通勤。

4 结论

本研究通过分析地铁通勤乘客的通勤模式,刻画了不同类型通勤人群画像,深入探讨了地铁客流特征及其规律。本研究采用 2023 年 3 月 21 日至 4 月 3 日共计 2 周 10 个工作日的 AFC 刷卡数据,筛选出工作日的通勤乘客,并识别乘客居住站点和工作站

点,然后选取了上班进站时间、下班进站时间、地铁通勤耗时 3 个指标,构建 GMM 模型,并进一步对各类乘客的居住站点和工作站点进行了空间分析,得到以下结论:

1) 地铁乘客通勤模式可以划分为经典通勤、错峰通勤、长距离通勤 3 类,其中经典通勤模式最多,占比 48.9%,长距离通勤模式其次,占比 33.4%,错峰通勤模式最少,占比 17.7%。

2) 从早晚通勤时间来看:经典通勤乘客通勤时间主要集中在 7:30-8:30 和 17:30-18:30,符合典型的通勤高峰时段;长距离通勤乘客通勤时间与经典通勤乘客相近,但略有提前,早晚高峰分别比第 1 类乘客提早 16 min 和 7 min;错峰通勤乘客的上班时间分布较为均匀,涵盖了 7:00-12:00 的整个时间段,下班时间集中在 20:00-22:30,避开了晚高峰。

3) 从通勤时长来看:经典通勤模式和错峰通勤模式的通勤时长比较适中,集中在 15~30 min;长距离通勤模式乘客的通勤时长主要集中在 30 min 以上,并且其上下班时间相较于经典通勤模式略微提前,这两个特征在一定程度上相互印证。

4) 从居住和工作站点的空间分布来看:3 类客流的工作站点呈中心城区单核集中分布态势,而居住站点则呈市区边缘多核分散态势。这种职住分离现象在长距离通勤乘客上表现得尤为明显。错峰通勤乘客的工作站点比其他两类更为集中,主要集中在餐饮和娱乐行业发达的商业区。

基于本研究成果,地铁运营公司可以有针对性地优化地铁班次以提高服务水平。例如,针对错峰通勤乘客,可以在相应时段增加列车班次。此外,本研究也表明城市新区需要大力推动产业发展、创造更多工作岗位,从而推动职住平衡发展,减少长距离通勤。未来的研究可以进一步结合实时数据和更先进的算法,或者结合乘客个人调查信息数据^[13]、移动轨迹数据等进行深入分析,从而更准确地了解乘客需求和行为模式,不断提升地铁系统的智能化管理水平。

参考文献

- [1] 韩宝明,余怡然,习喆,等. 2023 年世界城市轨道交通运营统计与分析综述[J]. 都市快轨交通, 2024, 37(1): 1-9. HAN Baoming, YU Yiran, XI Zhe, et al. Statistical analysis of urban rail transit operations worldwide in 2023: a review[J]. Urban rapid rail transit, 2024, 37(1): 1-9.
- [2] 交通运输部. 2023 年交通运输行业发展统计公报[EB/OL]. (2024-06-18)[2024-07-05]. https://www.gov.cn/lianbo/bumen/202406/content_6957901.htm.
- [3] 程小云,张学宇,薛顺然,等. 基于多维属性的轨道交通出行行为分类方法[J]. 交通运输工程与信息学报, 2020, 18(4): 166-174. CHENG Xiaoyun, ZHANG Xueyu, XUE Shunran, et al. Method of analyzing rail transit travel behavior based on multidimensional attributes[J]. Journal of transportation engineering and information, 2020, 18(4): 166-174.
- [4] 刘哲园,孟品超. 基于智能刷卡数据的地铁乘客分类研究[J]. 长春理工大学学报(自然科学版), 2022, 45(2): 116-123. LIU Zheyuan, MENG Pinchao. Research on classification of metro passengers based on smart card data[J]. Journal of Changchun University of Science and Technology (Natural Science Edition), 2022, 45(2): 116-123.
- [5] 倪汪凌,褚文斌. 基于 K-means++ 的轨道交通异常出行乘客分类研究[J]. 物流工程与管理, 2023, 45(5): 96-99. NI Wangling, CHU Wenbin. Research on rail transit abnormal travel passenger classification based on K-means++ Algorithm[J]. Logistics engineering and management, 2023, 45(5): 96-99.
- [6] 姚志刚,卢致远. 联合重复性与周期性的公交乘客个体出行规律分类[J]. 交通运输系统工程与信息, 2023, 23(5): 113-119. YAO Zhigang, LU Zhiyuan. A segmentation of bus passenger combining repeatability and periodicity of individual travel pattern[J]. Journal of transportation systems engineering and information technology, 2023, 23(5): 113-119.
- [7] 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.
- [8] 长沙市统计局. 长沙市 2023 年国民经济和社会发展统计公报[EB/OL]. (2024-04-28)[2024-07-05]. http://www.changsha.gov.cn/zfxxgk/fdzdgnr/tjxx/tjgb_134828/202404/t20240426_11427939.html.
- [9] FAROQI H, MESBAH M. Inferring trip purpose by clustering sequences of smart card records[J]. Transportation research part C: emerging technologies, 2021, 127: 103131.
- [10] JI Yanjie, CAO Yu, LIU Yang, et al. Research on classification and influencing factors of metro commuting patterns by combining smart card data and household travel survey data[J]. IET intelligent transport systems, 2019, 13(10): 1525-1532.
- [11] LIU Yunzhe, CHENG Tao. Understanding public transit patterns with open geodemographics to facilitate public transport planning[J]. Transportmetrica A: transport science, 2020, 16(1): 76-103.
- [12] SU Meiling, LIU Ling, CHEN Xiyang, et al. Exploration of the impact of built environment factors on morning and evening peak ridership at urban rail transit stations: a case study of Changsha, China[J]. SAE international journal of sustainable transportation, energy, environment, & policy, 2025, 6(2): 1-14.
- [13] 何静,徐钰婷. 考虑乘客需求的城市轨道交通服务质量评价[J]. 都市快轨交通, 2023, 36(1): 80-86. HE Jing, XU Yuting. Urban rail transit service quality evaluation considering passenger demand[J]. Urban rapid rail transit, 2023, 36(1): 80-86.

(编辑:傅依萱)