

人工智能驱动的城轨短时客流 预测方法综述

陈 峰¹, 张金雷²

(1. 北京交通大学土木建筑工程学院, 北京 100044; 2. 北京交通大学系统科学学院, 北京 100044)

摘 要: 随着城市轨道交通线网规模持续扩大和运营场景日益多元, 客流需求呈现出更复杂的时空特征, 对列车运行组织和客流管控等提出更高要求。短时客流预测是城市轨道交通运营管理的重要基础, 人工智能方法凭借较强的时空特征提取能力, 已成为提升预测性能的重要手段。本文围绕人工智能驱动的城市轨道交通短时客流预测方法展开综述。首先, 从预测场景、预测对象、数据基础、预测方法和评价指标 5 个维度构建任务分析框架; 其次, 梳理预测模型发展脉络; 再次, 面向进出站客流、起讫点(origin-destination, OD)客流、断面客流、多类型客流协同预测以及以轨道交通为骨干的多模式交通预测等任务, 总结相关研究进展和主要挑战; 最后, 从大语言模型、可信可解释预测、端到端预测优化一体化框架以及世界模型等方面展望其未来发展方向。研究结果表明: 城市轨道交通短时客流预测研究正由单一客流类型、单一精度评价和单一预测任务, 逐步转向多源感知、多类型协同与多指标评估融合发展; 未来研究将进一步聚焦通用适应性、不确定性感知、可信风险评估、决策导向预测以及世界模型驱动的动态推演, 构建面向复杂运营场景的一体化智能预测推演体系, 以支撑城市轨道交通精细化运营决策。

关键词: 城市轨道交通; 短时客流预测; 人工智能; 深度学习

中图分类号: U231

文献标志码: A

文章编号: 1672-6073(2026)04-0020-14

Artificial Intelligence-Based Short-Term Passenger Flow Prediction in Urban Rail Transit Systems: A Review

Chen Feng¹, Zhang Jinlei²

(1. School of Civil Engineering, Beijing Jiaotong University, Beijing 100044;

2. School of Systems Science, Beijing Jiaotong University, Beijing 100044)

Abstract: With the continued expansion of urban rail transit networks and the increasing complexity of operating scenarios, passenger demand exhibits more complex spatiotemporal patterns, posing higher requirements for train operation organization and passenger flow control. Short-term passenger flow prediction is an important basis for urban rail transit operation management and provides key support for operational decision-making. In recent years, artificial intelligence-based methods have become an important technical approach for improving short-term passenger flow prediction performance, owing to their strong capability to extract complex spatiotemporal features. This review focuses on artificial intelligence-based methods for short-term passenger flow prediction in urban rail transit systems. It first constructs a task analysis framework from five dimensions: prediction scenarios, prediction targets, data sources, prediction methods, and evaluation metrics. Second, the development trajectory of prediction models is systematically reviewed. Furthermore, recent studies and major challenges are summarized for different prediction tasks, including station inflow and outflow passenger flow prediction, origin-destination passenger flow prediction, section passenger flow prediction, multi-type passenger flow collaborative prediction, and multimodal traffic prediction with

收稿日期: 2026-06-13 修回日期: 2026-06-26

第一作者: 陈峰, 男, 博士, 教授, 从事轨道交通运营管理、人工智能与大数据、客流预测等相关研究, fengchen@bjtu.edu.cn

基金项目: 国家自然科学基金项目(71871027)

引用格式: 陈峰, 张金雷. 人工智能驱动的城轨短时客流预测方法综述[J]. 都市轨道交通, 2026, 39(4): 20-33.

rail transit as the backbone. Finally, future research directions are discussed from the perspectives of large language models, trustworthy and interpretable prediction, an end-to-end predict-and-optimize learning framework, and world models. This review shows that short-term passenger flow prediction in urban rail transit is evolving from single-flow-type, single-metric, and single-task prediction toward integrated development featuring multi-source perception, multi-type passenger flow collaboration, and multi-metric evaluation. Future research should further emphasize general adaptability, uncertainty awareness, trustworthy risk assessment, decision-oriented prediction, and world-model-driven dynamic deduction, with the aim of building an integrated intelligent prediction and simulation framework for complex operational scenarios and supporting refined operational decision-making in urban rail transit.

Keywords: urban rail transit; short-term passenger flow prediction; artificial intelligence; deep learning

城市轨道交通具有运量大、准时性高等特点，是支撑城市公共交通高效运行的骨干。截至 2025 年 12 月 31 日，中国内地共开通 343 条城市轨道交通线路，运营里程达到 11 710.3 km，全年客运量达到 332.4 亿人次，全年客运量较 2024 年增长 3.1%^[1]。随着线网规模持续扩大和客流强度不断提升，城市轨道交通客流呈现出更为复杂的时空特征，使列车运行组织、客流管控和运力配置等运营环节面临更高要求。尤其在早晚高峰、节假日和大型活动等场景下，客流易在短时间内发生显著波动，对城市轨道交通的稳定运营形成较大挑战。短时客流预测旨在预测轨道交通系统内未来某一时段的客流状态，是解决上述挑战的关键手段之一^[2]。近年来，基于人工智能的客流预测方法在复杂时空特征提取和非线性关系建模方面表现突出，为提升城市轨道交通短时客流预测精度提供了新的技术路径。在此背景下，对人工智能驱动的城市轨道交通短时客流预测方法进行系统梳理具有重要意义。现有城市轨道交通短时客流预测研究在模型结构、预测

对象、预测场景和评价体系等方面较为分散，亟需从人工智能赋能运营管理的视角进行系统归纳。鉴于此，本文构建涵盖研究基础、模型发展、研究对象和未来趋势的分析框架，系统梳理人工智能方法在短时客流预测中的应用进展、技术演化和应用边界，凝练当前研究的关键问题与未来发展方向。同时，本文总结不同方法在实际运营场景中的适用特点、部署难点与工程化挑战，可为城市轨道交通运营企业开展智能预测系统建设与工程应用提供参考。

1 城市轨道交通短时客流预测概述

本文围绕人工智能驱动的城市轨道交通短时客流预测方法展开综述，整体综述框架如图 1 所示。具体而言，首先对城市轨道交通短时客流预测进行概述，然后对模型的发展路线进行梳理，并面向不同研究对象总结相关研究进展与主要挑战，最后展望短时客流预测的未来发展趋势。在此框架下，研究基础是梳理模型发展脉络和归纳不同预测对象的前提。因此，有必要先明确城市轨道交通短时客流预测的基本概念。




图 1 综述框架示意

Figure 1 Overview of the review framework

城市轨道交通短时客流预测是指基于历史客流数据以及客流影响因素,对未来短时间内客流量进行预测,常见的时间粒度包括5 min, 15 min, 30 min 和 60 min 等。相较于中长期客流预测,短时客流预测更加注重预测实时性,可支撑城市轨道交通实时动态运营管理。总体而言,短时客流预测可从预测场景、预测对象、数据基础、预测方法和评价指标5个角度进行概述。

1.1 预测场景

确定预测场景是开展客流预测工作的第一步。在预测场景方面,城市轨道交通短时客流预测可根据运营环境和客流变化特征划分为常态场景和非常态场景。常态场景主要包括工作日、周末等规律性运营场景,其客流变化通常呈现明显的早晚高峰特征,具有较强的周期性和稳定性,是现有短时客流预测研究最为广泛的应用场景。

非常态场景则可进一步划分为外部扰动场景和内部扰动场景。其中,外部扰动场景主要包括节假日、大型赛事与演唱会、极端天气、公共卫生事件等轨道交通系统外部因素引起的客流异常波动。此类场景通常表现为需求规模的突增、突减或时空分布重构,具有显著的非平稳性和时空异质性。内部扰动场景则主要包括列车故障、信号设备故障、区间中断、车站封闭等轨道交通系统内部运营事故。与外部扰动场景相比,内部扰动不仅会改变客流需求规模,还会影响乘客出行路径选择、换乘行为及网络客流分布,引发客流在网络中的动态迁移与再分配,进而形成复杂的级联传播效应。因此,内部扰动场景下的客流预测不仅需要刻画客流需求变化规律,还需要考虑事故影响下的客流传播机理和路径重构过程。总体而言,非常态场景下客流往往表现出突发性、非平稳性和强时空异质性等特征,对预测模型的泛化能力、异常模式识别能力以及复杂场景适应能力提出了更高要求。

1.2 预测对象

在确定预测场景的基础上,可进一步确定预测对象。在预测对象方面,城市轨道交通短时客流预测对象主要包括进出站客流、起讫点(origin-destination, OD)客流以及断面客流等单一预测对象,以及多客流要素协同预测和以轨道交通为骨干的多模式交通协同预测。其中,进出站客流反映车站层面的客流强度,直接服务于车站客流组织^[3]; OD 客流刻画了乘客在线网中的起讫关系,能够反映网络层面的出行需求^[4];断面客

流反映线路区间的客流负荷^[5],与运力配置和交路设计密切相关。多客流要素协同预测^[6]强调同时建模进出站客流、OD 客流和断面客流等不同客流要素之间的内在关联,以提升多层级客流状态预测的一致性和完整性;以轨道交通为骨干的多模式交通协同预测^[7]则进一步考虑轨道交通与公交、出租车、共享单车等其他交通方式之间的需求转移和相互影响,为综合交通系统协同组织与一体化出行服务提供支撑。

1.3 数据基础

在数据基础方面,城市轨道交通短时客流预测数据主要依靠自动检售票(automatic fare collection, AFC)系统刷卡数据、网络拓扑结构以及客流影响因素数据。其中 AFC 刷卡数据记录了乘客的进出站时间、进出站名称等信息,可用于提取进出站客流和 OD 客流时序数据。网络拓扑结构主要包含线网连通关系,用于刻画不同车站客流之间的空间依赖。客流影响因素是指天气、兴趣点(point of interest, POI)、节假日、大型活动等能够影响客流变化的外部诱因,有助于提升预测的准确性。

1.4 预测方法

在预测方法方面,现有研究通常将城市轨道交通短时客流预测方法划分为统计学习方法、机器学习方法、深度学习方法以及大模型驱动方法等。确定预测方法的同时,需要考虑模型输出形式,因此从预测输出角度,相关方法又可分为确定性预测和不确定性预测。确定性预测主要输出未来短时客流量的点预测结果,不确定性预测则进一步给出客流变化的可能范围或概率分布。本文后续将按照模型发展脉络对预测方法进行系统梳理与分析。

1.5 评价指标

在评价指标方面,现有研究通常使用平均绝对误差(mean absolute error, MAE)、均方根误差(root mean squared error, RMSE)、平均绝对百分比误差(mean absolute percentage error, MAPE)和加权平均绝对百分比误差(weighted mean absolute percentage error, WMAPE)等,其中 MAE 反映预测值与真实值之间的平均偏差, RMSE 对峰值更加敏感, MAPE 和 WMAPE 用于衡量相对误差水平。随着不确定性预测研究的发展,连续排序概率得分(continuous ranked probability score, CRPS)、预测区间覆盖率(prediction interval coverage probability, PICP)和预测区间宽度(prediction interval width, PIW)等指标也逐渐被用于评价概率预测或区间预测结果。其

中, CRPS 可用于衡量预测分布与真实观测值之间的差异, PICP 用于评价真实值落入预测区间的比例, PIW 则反映预测结果的不确定性范围。

后续本文将进一步系统梳理城市轨道交通短时客流预测模型发展, 并以预测对象为主线, 结合预测场景和预测输出, 对城市轨道交通短时客流预测研究进

行系统性归纳总结。

2 城市轨道交通短时客流预测模型发展

城市轨道交通短时客流预测一直是轨道交通领域的研究热点, 预测方法逐步从传统统计建模方法向基于人工智能的方法发展, 具体如图 2 所示。




图 2 模型发展概述示意

Figure 2 Overview of the model development

早期研究多采用历史平均、自回归差分移动平均模型(autoregressive integrated moving average, ARIMA)等统计方法对客流的趋势和周期性进行建模。这类模型结构简单, 难以充分刻画客流中复杂的非线性特征和时空依赖。随着机器学习技术的发展, 支持向量机^[8]、随机森林等机器学习方法逐渐被用于短时客流预测。这些方法相较于统计方法能够更好地刻画客流中的非线性关系, 并可以结合天气、节假日信息等因素提升预测精度。然而, 这类方法很大程度上依赖人工特征构造, 普遍用于车站级客流预测, 在线网级客流预测方面存在局限性。近年来, 基于深度学习的方法成为主流。相关研究通常利用循环神经网络(recurrent neural network, RNN)及其变体建模时间依赖^[9], 利用卷积神经网络(convolutional neural network, CNN)^[10]、图卷积神经网络(graph convolutional network, GCN)^[11]等建模空间依赖, 并通过组合多类模型结构实现时间和空间依赖联合建模^[12-13]。进一步地, 注意力机制的发展增强了模型对长时间依赖的捕捉能力。总体而言,

深度学习方法能够在海量数据中自适应提取复杂的时空依赖, 但其模型结构通常较为复杂, 可解释性较差。随着大模型技术的持续发展^[14-17], 基于大语言模型的时空预测模型得到了广泛关注, 这类方法通过对时间序列重编程^[18]或者转换为 token^[19]等方式, 将时间序列转化为适合大模型处理的输入形式, 借助大模型泛化能力、预训练知识和提示工程, 在少样本和零样本场景中的预测性能展现良好。然而, 由于大语言模型参数规模较大, 其训练和推理过程通常需要较高的计算资源, 如何提高模型训练效率仍是后续研究需要关注的问题。

近年来, 随着城市轨道交通运营管理对决策鲁棒性要求的提高, 短时客流预测研究逐渐由传统确定性预测向不确定性预测拓展。相关研究通常基于贝叶斯学习^[20]、分位数回归^[21]、深度集成学习^[22]以及生成模型^[23]等方法, 在输出客流点预测结果的同时, 进一步给出预测区间或概率分布, 从而量化预测结果的不确定性。这类方法能够为后续客流管控和应急调度提供更加可靠的决策依据, 已成为短时客流预测领域的重

要发展方向之一。

3 面向不同客流对象的城市轨道交通短时客流预测研究

根据预测对象的不同,现有城市轨道交通短时客流预测研究可进一步划分为进出站客流预测、OD 客流预测、断面客流预测以及多类型客流协同预测等方

向。不同预测对象分别服务于站点客流感知、网络需求分布刻画、线路断面负荷识别以及多层级客流状态协同刻画,这些对象共同构成了城市轨道交通短时客流预测研究的重要体系^[24]。面向不同客流对象的城市轨道交通短时客流预测研究总结具体如图 3 所示。下文将围绕上述预测任务,分别梳理其研究进展与方法特点。

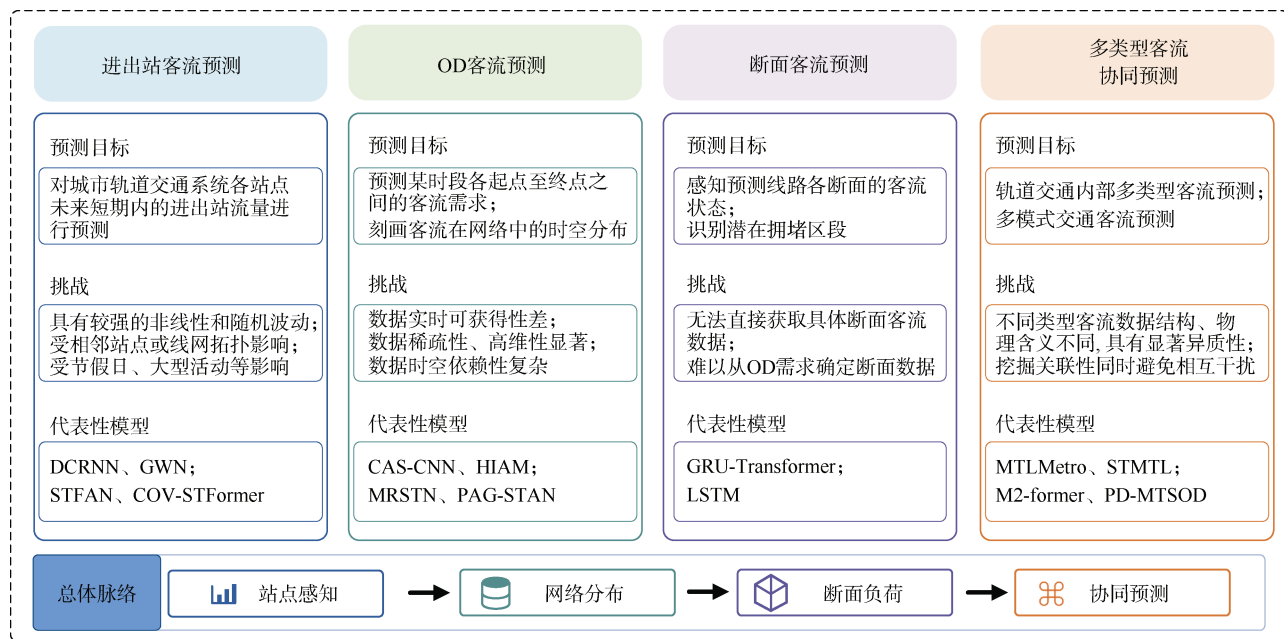


图 3 面向不同客流对象的预测研究概述

Figure 3 Overview of forecasting studies for different passenger flow types

3.1 进出站客流预测

城市轨道交通短时进出站客流预测是指基于 AFC 记录的乘客进出站数据,结合时间属性、站点特征、线网结构等多源外部信息,对各站点未来短期内的进出站客流量进行预测。进出站客流量直接反映了车站层面的客流集散强度,是客流组织、运能配置的重要依据。根据预测结果,运营管理部门可以准确识别重点车站和高风险时段,以便及时开展客流管控、运能调整等措施,从而降低站点拥堵风险,避免服务水平下降。

然而,城市轨道交通短时进出站客流预测仍面临多方面挑战。首先,进出站客流在短时尺度下具有较强的非线性和随机波动性^[25],尤其在早晚高峰时段,客流快速形成高峰,随后迅速消散,模型难以利用历史均值获得稳定的预测结果。其次,不同站点在区位功能、周边土地利用和客流结构方面存在明显差异,导致不同站点的进出站客流量呈现异质性^[11]。同时,站

点进出站客流的演化过程并非孤立,而是受到相邻站点和线网拓扑关系等多方面影响,模型需要进一步考虑站点间的空间依赖性^[26]。此外,节假日、大型活动和恶劣天气等外部因素会严重影响系统运营,导致客流具有显著的随机性和突发性,使非常态场景下的短时进出站客流预测更加困难^[27]。因此,城市轨道交通短时进出站客流预测是一项具有重要意义且充满挑战性的任务。

针对上述挑战,近年来,学者们从模型架构和数据融合等方面入手开展了大量研究,在短时进出站客流预测上取得了显著突破。在模型架构方面,现有研究逐渐由单一预测模型转向多模型融合与时空联合建模,通过结合机器学习、循环神经网络、图卷积神经网络和注意力机制等方法,提升模型对进出站客流时空依赖关系的刻画能力。例如,赵阳阳等^[28]结合经验模态分解与长短时记忆网络,降低客流时间序列噪声并提升预测效果;王雪琴等^[29]融合注意力机制、时空

图卷积门控递归单元,同时提取客流的空间关系与时间依赖性。针对不同类型站点进出站客流的时空分布不均衡性,王金水等^[30]通过站点分类和随机森林-门控循环单元组合模型,实现不同类型站点的短时客流预测。进一步地,Li等^[31]提出了交互图网络,从拓扑连通性、客流模式相似性和时间关联性等角度构建站间交互图,以刻画多站点客流空间依赖,实现站点级进出站客流的准确预测;Gao等^[32]提出了正则化时空图卷积网络,利用个性化增强图卷积网络和多头自注意力机制捕捉客流时空特征;Wang等^[33]引入超图结构刻画站点和乘客出行模式间的高阶关系,在此基础上,利用超图卷积和时空块提取时空特征,实现节点级客流预测。

在数据融合方面,针对节假日、大型活动和突发事件等外部因素显著影响客流波动的挑战,相关研究引入多源外部数据以提升事件场景下的预测性能。例如,惠阳等^[34]综合考虑节假日、时间段、站点和天气等因素,构建基于粒子群优化的BP神经网络客流预测模型。杨静等^[35]融合历史客流、大型活动数据与实时AFC数据,提出一种大型活动散场期间的地铁站点短时客流预测模型。冯树民等^[36]利用客流偏差率量化雨雪天气对客流波动的影响,并结合长短时记忆网络(long short-term memory, LSTM)模型对雨雪天气下的轨道交通客流进行预测。Ni等^[37]引入社交媒体数据刻画突发事件对地铁客流的扰动影响,并结合线性回归与季节性差分自回归滑动平均模型(seasonal autoregressive integrated moving average, SARIMA)模型提升预测精度。针对疫情等突发公共卫生事件,Zhang等^[38]引入疫情确诊病例人数以及相关社交媒体数据,构建多源数据融合模块挖掘疫情对地铁进站客流的影响,有效刻画了疫情防控期间客流的演化趋势。面向大型活动引发的短时客流剧烈波动,Xue等^[39]融合社交媒体数据和目标站点周边车站进站流数据,构建多元扰动建模的混合深度神经网络,实现活动期间目标站点客流短时预测。

总体而言,现有研究从模型架构和数据融合等方面对城市轨道交通进出站客流预测展开了深入研究。相关方法能够较好刻画站点客流的时间依赖、空间关联和外部事件扰动影响,显著提升了短时预测精度。然而,在节假日、大型活动、极端天气和突发事件等非常态场景下,进出站客流仍具有较强的随机性和非平稳性,模型的跨场景泛化能力、非常态样本学习能

力和预测结果可靠性仍需进一步提升。

3.2 OD 客流预测

在站点级进出站客流预测的基础上,城市轨道交通OD客流预测进一步关注乘客在轨道交通网络中的起讫点分布,其目标是基于历史客流数据和线网结构等信息,预测未来某一时段内各起点站至各终点站之间的客流需求,即未来OD矩阵。相比仅刻画车站进站量或出站量的站点级客流预测,OD客流预测能够更细致地揭示客流在轨道交通网络中的时空分布,从而为运营管理部门掌握乘客出行结构、识别重点OD站点关联提供依据。同时,OD客流也是断面客流推算和客流分配的重要输入,可进一步支撑列车运能配置、断面拥挤识别和运行组织优化。

然而,相比进出站客流预测,短时OD客流预测是一项更具挑战性的任务。现有文献对城市轨道交通短时OD客流预测任务所面临的挑战进行了系统总结^[40],主要包括以下几项:

1) OD客流数据实时可获得性。在城市轨道交通系统中,乘客的出行记录往往通过AFC刷卡数据得以记录。考虑到出行时长的影响,完整的进出站信息无法及时获得,因此,OD客流数据的收集具有滞后性,一般无法实时获得完整的OD客流数据。

2) OD客流数据稀疏性。由于城市不同区域在用地功能、就业分布和出行吸引强度方面存在差异,地铁站点之间的OD需求并非均匀分布。居住区与商业区、就业区或交通枢纽之间通常具有较高的客流联系,而部分郊区站点或功能联系较弱的站点之间客流较低。因此,OD矩阵往往呈现高维稀疏特征,增加了模型对低频OD对的特征学习难度,进而影响预测结果的稳定性。

3) OD客流数据高维性。在包含 N 个站点的城市轨道交通系统中,OD矩阵的维度通常为 $N \times N$,其规模随车站数量呈平方级增长,显著高于站点级进出站客流预测任务。高维输出不仅增加了模型训练和实时预测的计算复杂度,也提高了OD对之间时空依赖关系建模的难度。因此,如何降低OD客流矩阵的高维建模负担,是城市轨道交通OD预测的重要问题。

4) OD客流复杂的时空依赖性。OD客流同时受到时间变化、空间结构等方面的影响。在时间维度上,OD客流具有明显的日内、日间周期特征;在空间上,不同OD对之间并非相互独立,其变化可能受到起终点属性、相邻站点以及功能相似区域的共同影响。如

何有效刻画OD对之间复杂的时空关联和网络传播关系,是城市轨道交通OD需求预测面临的重要挑战。

针对上述挑战,近年来,学者们开展了广泛研究,取得颇有成效的结果。具体来说,在OD数据的实时可获得性方面,Zhang等^[40]通过进出站客流门控机制融合实时进站流与历史OD流信息,以估计实时OD客流。Liu等^[41]提出异构信息聚合模型,将已完成出行需求与尚未完成出行的潜在目的地估计相结合,缓解在线OD实时信息不完整问题。Noursalehi等^[42]则利用历史完整OD需求和离散小波变换,从多分辨率角度刻画OD需求的时空依赖。

针对OD客流矩阵的稀疏性挑战,Zhang等^[40]提出动态OD矩阵压缩模块,根据预设阈值筛选需求较高的OD对,并聚合其他低需求OD对,从而构建相对稠密的压缩OD矩阵,以降低矩阵的稀疏程度。Zhuang等^[43]则从概率建模角度出发,引入零膨胀负二项分布刻画稀疏OD矩阵中大量零值和过度离散现象,有效描述OD出行需求的稀疏分布特征。此外,Zhang等^[44]从损失函数设计角度出发,提出基于时变权重的掩码损失函数,降低稀疏OD需求对模型训练的干扰。

针对OD客流矩阵的高维性问题,Chu等^[45]从数据表示角度出发,构建OD张量结构,以在压缩维度的同时尽可能保留OD流的空间信息。在此基础上进一步提出OD张量排列与矩阵化方法,以降低高维OD张量带来的建模复杂度。Ke等^[46]则将OD客流矩阵重构为基于OD对的时序数据,以缓解OD矩阵的高维输出压力。

针对复杂时空依赖建模问题,申惠涛等^[47]提出基于生成对抗网络的地铁OD需求短时预测模型,利用生成对抗网络学习OD客流的时空分布特征。陈鹤林等^[48]通过图注意力网络提取OD对空间关联,利用门控循环单元(gated recurrent unit, GRU)融合时序特征,并借助双层Transformer分别捕捉局部和全局时空依赖。苏焕银等^[49]针对OD需求时空分布复杂的问题,提出基于多头注意力机制的时空图卷积模型,通过提取历史客流的波动性、趋势性和周期性特征,并构建虚拟OD拓扑图,刻画OD对之间的复杂关联关系。Wang等^[50]基于进站客流、出站客流和OD客流分别构造邻阶超图和语义超图,并提出多通道超图卷积网络以捕捉OD客流中复杂的时空关联性。Liu等^[51]提出一个细粒度的时空感知机用于OD需求预测,从通道、起点、终点和趋势等多个角度,充分建模复杂的时空

依赖性。面向非常态和突发扰动场景,Zou等^[52]引入迁移学习思想,利用历史事故知识辅助目标场景预测,提升事故场景下OD客流预测的准确性与鲁棒性。

总体而言,现有研究围绕城市轨道交通OD客流预测中的实时可获得性、稀疏性、高维性和复杂时空依赖等问题,从实时信息补全、矩阵压缩、概率建模和深度时空特征提取等方面进行了系统探索,有效提升了短时OD客流预测精度。OD客流预测能够揭示乘客在轨道交通网络中的起讫分布和出行结构,为断面客流推算、运能配置和运行组织优化提供重要输入。然而,低需求OD对预测、非常态场景下的跨场景泛化以及预测结果可靠性等问题仍需进一步研究。

3.3 断面客流预测

在掌握城市轨道交通客流时空分布的基础上,运营管理部门需要进一步感知和预测线路各断面的客流状态。断面客流直接反映线路区间的客流负荷水平,是运营企业编制列车运行图、确定运力配置和交路组织等的核心依据。准确的断面客流预测有助于运营管理部门掌握未来各区段的客流需求变化,科学制定列车开行方案、优化运力投放,并为行车组织调整和重点区段客流管控提供决策支持。同时,通过对高负荷断面的提前识别,还能及时发现潜在拥挤风险,避免局部区段出现运能不足、客流积压等问题,从而提升城市轨道交通系统的运营效率和服务质量。

然而,相比进出站客流和OD客流预测,断面客流预测面临更高的数据获取和建模难度。一方面,AFC数据只能记录乘客的进站和出站信息,无法直接观测乘客在各线路区间上的实际通过状态;另一方面,在多路径和换乘条件下,乘客的实际出行路径、换乘选择和区间通过过程具有不确定性,使得断面客流难以由OD需求直接确定。因此,如何结合OD需求、线网拓扑、路径选择等信息,准确推断并预测断面客流是核心难点。

围绕上述问题,早期研究主要基于既有OD需求开展客流分配,以推算线路和断面客流。例如,林湛等^[53]、陈培文等^[54]分别从换乘惩罚、有效路径搜索和改进Logit模型角度刻画乘客路径选择行为。费爽^[55]则进一步考虑了乘客对路网的熟悉程度,构建基于多项Logit模型的路径选择模型,实现路网客流分配。

随着城市轨道交通精细化运营需求的提升,相关研究逐渐由静态客流分配拓展至未来时段断面客流预测,即在路径选择和线网拓扑建模的基础上,进一步

结合历史客流演化规律和深度学习模型,对线路断面负荷进行提前预测。例如,何明等^[56]、张建旭等^[57]分别从出行引力、出行阻力和进出站客流关联角度构造断面客流特征,并结合深度学习模型进行预测。曹凯鑫^[58]通过路径分配和列车客流分配生成断面客流,再利用循环神经网络预测未来断面负荷。Zhang 等^[59]则将客流分配理论与计算图相结合,为断面客流推断与预测提供了新的建模思路。

总体而言,断面客流需求预测能够将 OD 需求分析进一步延伸至线路区间客流,为运能配置提供最直观的数据支撑,但仍需解决真实断面客流数据获取困难、路径选择复杂以及客流分配误差等关键问题。

3.4 多类型客流协同预测

近年来,城市轨道交通客流预测研究逐渐由单一客流类型预测向多类型客流协同预测拓展。多类型客流协同预测旨在统一建模框架下同时预测不同类型的客流,并通过挖掘不同客流序列之间的潜在关联提升整体预测性能。根据协同预测对象的不同,相关研究可进一步分为两类:一类是城市轨道交通系统多类型客流联合预测,主要面向进出站客流和 OD 客流等不同轨道客流类型的协同建模;另一类是以城市轨道交通客流为核心的多模式交通流量协同预测,重点刻画轨道交通、常规公交、出租车等不同交通方式之间的客流关联与相互影响。

尽管多类型客流协同预测能够同时预测多种客流数据,但其建模过程仍面临较大挑战:一方面,不同类型客流在数据结构、空间尺度和物理含义上存在明显差异,如进出站客流对应站点级序列,OD 客流对应高维矩阵,因而如何实现异质客流数据的统一表示和联合建模较为困难;另一方面,不同类型客流之间既存在相互联系,又具有各自独立的时空演化规律,如何充分挖掘跨类型关联特征,并避免联合训练中不

同任务之间的相互干扰,是提升协同预测效果的关键。

围绕上述问题,现有研究大多基于多任务学习框架^[60]开展协同预测。在城市轨道交通系统多类型客流联合预测方面,Huang 等^[6]和 Zhao 等^[61]通过多任务学习和共享嵌入机制实现进出站客流与 OD 流之间的信息共享。Qiu 等^[62]和杨静等^[63]利用图神经网络、注意力机制和时序建模方法刻画不同客流任务之间的时空耦合关系。沈拓^[64]进一步通过交互注意力和 Seq2Seq 结构增强不同任务之间的特征交互。

以城市轨道交通客流为核心的多模式交通流预测,旨在刻画轨道交通、公交、出租车等不同交通方式之间的客流交互影响,从城市层面反映整体出行需求变化。近年来,学者们对该类任务展开了深入研究,以期同时处理多模式交通数据在时空结构和数据形态上的差异,并建模不同交通方式之间的替代、互补和联动关系。例如,Yang 等^[65]和 Yang 等^[7]基于多任务学习和 Transformer 结构开展区域级与网络级多模式进站流预测,分析地铁、公交和出租车等交通方式之间的交互关系。随后,部分研究进一步引入超图结构、异构图结构和跨模式图结构,以刻画多模式交通需求之间的高阶空间依赖和跨模式关联^[66-68]。此外,江丽英等^[69]、吴媚^[70]和韩浩东等^[71]分别从专家混合、时空异质解耦和多任务注意力机制等角度建模不同交通模式之间的共性与差异性,提升多模式交通流预测性能。

总体而言,多类型客流协同预测突破了单一客流类型预测的局限,能够在统一框架下协同建模不同客流之间的时空关联关系,并同时输出多种客流预测结果,为城市轨道交通及多模式交通系统的精细化运营提供更全面的需求数据支撑。

为清晰直观地呈现各类预测模型的核心差异,城市轨道交通短时客流预测模型的空间建模、时间建模、外部信息融合和实验数据信息等关键维度对比如表 1 所示。

表 1 城市轨道交通短时客流预测模型对比

Table 1 Comparison of short-term passenger flow prediction models in urban rail transit systems

预测对象	代表模型	时间建模	空间建模	外部信息	实验数据集
进/出站 客流预测	DSTHGCN ^[33]	多重周期模式时间卷积层	超图卷积层	—	BJMF15, HZMF19
	COV-STFormer ^[38]	因果卷积-概率稀疏 注意力机制	自适应多图卷积网络	疫情确诊数据 社交媒体数据	NNMetro
	MDB-HDNN ^[39]	深度神经网络	空间注意力	社交媒体数据	BJMetro (Station-level)
OD 客流预测	CAS-CNN ^[4]	通道注意力机制	分离卷积层	—	BJMetro2016, BJMetro2018
	HIAM ^[41]	图卷积门控循环单元	图卷积门控循环单元	—	SHMOD, HZMOD
	MRSTN ^[42]	卷积长短时记忆网络	多分辨率空间特征提取模块	天气日期信息	HKMTR

续表

预测对象	代表模型	时间建模	空间建模	外部信息	实验数据集
OD 客流预测	PAG-STAN ^[40]	多重周期注意力机制、 双向长短时记忆网络	自适应图卷积-长短时记忆网络	疫情相关数据 日期属性数据	NNMOD, BJMOD
断面 客流预测	GRU-Transformer ^[56]	门控循环单元	—	天气日期信息	HZMetro
	LSTM ^[57]	长短时记忆网络	—	—	CQMetro
多类型客流 联合预测(进 出站客流、 OD 客流)	MTLMetro ^[6]	门控循环单元	图神经网络	—	CDMetro
	AGSECIN ^[61]	自适应供需共享嵌入网络	图注意力网络	—	BJMetro
	STMTL ^[62]	时间编码-门控循环单元	多图通道注意力网络	—	NNMetro
多模式交通 客流预测	M2-former ^[7]	多时间关联注意力机制	多空间关联自适应图卷积网络	—	Beijing (Taxi, Bus, Metro)
	PD-MTSOD ^[66]	注意力机制	超图卷积网络	—	Beijing (Bus, Metro); New York (Metro, Bike)
	MCSTEN ^[68]	时间-Transformer、 双向时间卷积网络	空间-Transformer、 自适应图卷积网络	—	New York (Taxi, Bike, Metro); Chicago (Taxi, Bike)

4 未来发展趋势

随着城市轨道交通系统规模持续扩大和运营场景日益复杂，未来城市轨道交通短时客流预测不仅面临模型精度提升等学术研究问题，还面临预测需求定义不清晰、应用场景复杂以及模型部署成本较高等工程应用挑战。

4.1 工程应用层面面临的挑战

在工程应用层面，当前运营管理部门对于客流预测的需求呈现显著的多样化和碎片化特征，不同部门关注的预测对象、预测时长和时间粒度均存在明显差异。例如，列车运行图编制通常关注日尺度和小时尺度的断面客流预测，车站客流组织更加关注 5 min 至 15 min 粒度的进出站客流预测，而节假日运输组织则需要周尺度甚至月尺度的客流需求预测。此外，不同城市在线网规模、客流特征和运营模式方面存在显著差异，使得现有预测模型往往需要进行大量场景适配和重新训练才能投入应用。因此，未来城市轨道交通客流预测的发展不仅需要关注模型性能提升，更需要以实践应用为导向，构建面向多场景、多尺度、多任务的通用预测框架，实现从“针对单一场景构建专用模型”向“一个模型服务多类运营需求”的转变。理想情况下，一个统一的预测模型能够同时支持进出站客流、OD 客流和断面客流预测，兼顾 5 min、15 min、30 min 及更长时间尺度的预测需求，并能够适应常态和非常态场景下的客流变化规律，从而显著降低模型部署和应用门槛。

然而，实现这一目标仍面临诸多挑战：一方面，构建覆盖不同城市、不同运营模式以及常态与非常态场景的大规模高质量数据集难度极大，数据共享和标

准统一问题尚未得到有效解决；另一方面，交通领域垂直大模型的训练需要大量计算资源、长期数据积累和持续迭代优化。同时，兼具交通运输专业知识与人工智能技术背景的复合型人才相对缺乏，在一定程度上制约了相关技术的研发与落地。因此，未来城市轨道交通短时客流预测的发展不仅需要关注算法创新，更需要在数据体系建设、行业基础模型构建、计算资源支撑以及跨学科人才培养等方面形成协同推进机制。

4.2 学术研究层面未来发展方向

在学术研究层面，秉承工程实践指导学术研究的理念，结合人工智能技术，未来城市轨道交通短时客流预测学术研究路径可概括为“能预测、敢使用、会决策、会推演”。其中，“能预测”强调构建跨场景、跨任务的通用客流预测基础模型；“敢使用”强调提升预测结果的可信性与可解释性；“会决策”强调客流预测与运营优化的深度融合；“会推演”强调构建 AI 驱动的城市轨道交通系统动态演化的世界模型。四者共同构成未来城市轨道交通智慧化运营的理论基石。

4.2.1 能预测：大模型驱动通用客流预测基础模型

当前城市轨道交通客流预测普遍采用针对特定场景构建专用模型的模式，不同预测对象、不同预测粒度以及不同运营场景往往需要分别建立预测模型。该模式虽能够针对具体任务进行优化，但模型开发、部署和维护成本较高，跨城市和跨场景迁移能力有限。未来城市轨道交通客流预测有望从面向单一任务的专用模型逐步发展为面向多场景、多尺度和多任务的通用预测基础模型。

近年来,大语言模型凭借强大的上下文理解、知识迁移和推理能力,在自然语言处理及相关领域受到广泛关注。由于时序数据同样具有连续依赖、周期变化和模式演化等序列特征,学者们^[72-73]开始探索将大语言模型应用于时间序列预测任务,以发挥其在长序列建模、模式识别和少样本泛化方面的潜在优势,利用预训练大模型的特征学习表示能力,提取复杂的时序特征。借助大语言模型强大的知识表示、迁移学习和推理能力,未来模型不仅需要能够统一处理进出站客流、OD 客流和断面客流等不同预测任务,还能够融合天气、活动、文本公告和社交媒体等多源异构信息,实现复杂场景下的预测与推理。未来研究的重要目标是构建覆盖多城市、多场景和多任务的行业级基础大模型,使城市轨道交通客流预测真正具备跨场景泛化和跨任务迁移能力,实现从“针对单一场景构建专业模型”向“一个模型服务多类需求”的转变。

4.2.2 敢使用:可信可解释客流预测

预测模型要真正服务于运营管理,仅有较高预测精度是不够的,还需要让运营人员理解、信任并愿意使用预测结果。未来可信可解释客流预测将成为人工智能驱动的客流预测研究的重要发展方向。一方面,模型需要能够量化预测结果的不确定性,给出客流变化的可能范围和风险水平,使运营管理部门能够根据不同风险等级制定相应策略;另一方面,模型需要解释预测结果形成的原因,识别关键时间段、重点车站、重要 OD 对以及天气、活动等影响因素。

现有文献虽然没有系统地“可信可解释客流预测”展开研究,但已从物理信息引导损失函数、不确定性预测和可解释时空建模等方面进行了初步探索。例如,Zhang 等^[40]通过在损失函数中嵌入实时进站流与 OD 客流的数量关系增强模型的训练,提升预测结果的可信性;郭旷等^[74]通过不确定性预测和概率预测刻画预测结果的风险范围,为运营决策提供更加可靠的依据;Tang 等^[75]提出可解释时空图神经网络框架,同时提升预测精度和解释质量。总体来看,可信可解释客流预测仍处于发展初步阶段,未来研究还需要进一步融合交通机理、客流守恒关系和线网拓扑约束,将数据驱动方法与领域知识有机结合,构建既具备高预测精度,又能够被理解、验证和信任的客流预测模型,推动人工智能预测模型真正进入运营生产体系,实现从“预测准确”向“预测可信”的转变。

4.2.3 会决策:端到端“预测与优化”一体化研究

现有城市轨道交通客流预测大多停留在预测层面,而实际运营管理更加关注如何利用预测结果制定最优决策。未来研究需要突破传统“先预测、后优化”的两阶段框架限制,构建面向运营目标的端到端“预测—优化”一体化模型。通过将列车运行图编制、运力配置、交路组织、客流管控等运营决策目标直接融入模型训练过程,实现预测任务与运营决策的协同优化。针对两阶段框架限制,学者们提出了面向下游决策的端到端“预测—优化”一体化模型,通过最小化决策损失提升模型的决策效果^[76]。目前,一体化模型在电力系统^[77]、仓储库存管理^[78]以及航运系统^[79]等领域得到初步应用。相比之下,城市轨道交通系统中的运营优化尚缺少成熟的一体化研究框架,上游客流需求预测任务与下游运营决策仍相互割裂。未来研究可以借鉴端到端一体化思想,构建面向下游决策的城市轨道交通客流需求预测与列车运行图优化一体化框架。进一步地,还有望融合强化学习、生成式人工智能以及智能体技术,构建具备自主感知、预测、决策和反馈能力的智能运营系统,使客流预测从单纯的信息提供工具发展为运营决策生成工具,实现从“知道未来客流”向“知道如何决策”的转变。

4.2.4 会推演:世界模型驱动的系统动态演化仿真

预测未来状态并不意味着能够理解未来如何演化。未来城市轨道交通客流预测有望进一步发展为系统级动态推演与仿真框架。世界模型^[80]是一类用于刻画系统动态演化的可学习 AI 模型,旨在通过学习环境状态、外部扰动、行动策略和未来结果之间的关系,对系统运行过程进行模拟与推演。目前,世界模型在自动驾驶^[81]和交通仿真^[82]领域得到初步应用。相比之下,城市轨道交通系统演化领域尚缺少成熟的客流世界模型研究。对于城市轨道交通系统而言,未来研究可以借鉴世界模型思想,构建融合客流需求生成、乘客路径选择、断面传播、列车运行组织以及运营管控策略的统一世界模型,实现客流状态与运营状态的联合推演。在此基础上,不仅能够预测未来客流变化,还能够评估不同调度策略、限流方案和运力配置方案可能产生的影响,实现“预测未来”与“评估未来”的统一。AI 驱动的世界模型与数字孪生等仿真技术相结合后,有望构建更加智慧化的城市轨道交通智能推演平台,为运营部门提供实时仿真、策略验证和风险评估,实现从“预测未来”向“推演未来”的转变。

5 结论

本文围绕人工智能驱动的城市轨道交通短时客流预测研究进行了系统梳理,主要结论如下。

1) 城市轨道交通短时客流预测研究已形成较为完整的研究体系。本文从预测场景、预测对象、数据基础、预测方法和评价指标5个方面对相关研究进行了归纳,明确了短时客流预测任务的基本内涵、关键要素和评价指标。

2) 短时客流预测方法呈现出由传统统计方法、机器学习方法向深度学习方法持续演进的趋势,并进一步拓展至大语言模型赋能预测和不确定性预测等新方向。模型能力也逐步从单一时间序列拟合转向复杂时空关联建模、多源信息融合和风险感知预测。

3) 现有研究对象不断扩展,已由进出站客流预测逐步延伸至OD客流、断面客流、多类型客流协同预测,以及以轨道交通为骨干的多模式交通预测。然而,不同客流类型之间的耦合关系刻画、稀疏高维数据建模、多源异构信息融合和模型泛化能力仍是当前研究面临的主要挑战。

4) 未来城市轨道交通短时客流预测研究将进一步面向复杂运营场景和精细化运营决策需求,重点关注大语言模型赋能的场景理解与知识增强预测、可信可解释预测、不确定性感知与风险评估、端到端“预测—优化”一体化建模,以及世界模型驱动的系统仿真与动态推演,从而构建更加通用、可信和决策导向的一体化智能预测体系。

参考文献

- [1] 交通运输部. 2025年中国内地城市轨道交通运营数据统计分析[J]. 现代城市轨道交通, 2026(2): 102-103.
- [2] 凌晨, 许心越, 叶子扬, 等. 城市轨道交通短时客流预测研究综述及展望[J]. 铁道运输与经济, 2025, 47(7): 44-55.
Ling Chen, Xu Xinyue, Ye Ziyang, et al. Review and prospects of short-term passenger flow prediction in urban rail transit[J]. Railway Transport and Economy, 2025, 47(7): 44-55.
- [3] 江志彬, 刘伟, 韩彦钊, 等. 城市轨道交通网络客流大数据可视化[J]. 城市交通, 2018, 16(2): 70-75+8.
Jiang Zhibin, Liu Wei, Han Yanzhao, et al. Big passenger flow data visualization for urban rail transit network[J]. Urban Transport of China, 2018, 16(2): 70-75.
- [4] Zhang J L, Che H S, Chen F, et al. Short-term origin-destination demand prediction in urban rail transit systems: a channel-wise attentive split-convolutional neural network method[J]. Transportation Research Part C: Emerging Technologies, 2021, 124: 102928.
- [5] He D Q, He Y, Zhang L, et al. Train operation scheme of short-turning routing in urban rail transit based on passenger travel[J]. Transportation Research Record: Journal of the Transportation Research Board, 2024, 2678(12): 2125-2139.
- [6] Huang H, Mao J N, Liu R H, et al. MTLMetro: a deep multi-task learning model for metro passenger demands prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(9): 11805-11820.
- [7] Yang Y J, Zhang J L, Yang L X, et al. Network-wide short-term inflow prediction of the multi-traffic modes system: an adaptive multi-graph convolution and attention mechanism based multitask-learning model[J]. Transportation Research Part C: Emerging Technologies, 2024, 158: 104428.
- [8] Sun Y X, Leng B, Guan W. A novel wavelet-SVM short-time passenger flow prediction in Beijing subway system[J]. Neurocomputing, 2015, 166: 109-121.
- [9] Ma X L, Tao Z M, Wang Y H, et al. Long short-term memory neural network for traffic speed prediction using remote microwave sensor data[J]. Transportation Research Part C: Emerging Technologies, 2015, 54: 187-197.
- [10] Zhang J B, Zheng Y, Qi D K. Deep spatio-temporal residual networks for citywide crowd flows prediction[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2017, 31(1): 1655-1661.
- [11] He Y X, Li L S, Zhu X T, et al. Multi-graph convolutional-recurrent neural network (MGC-RNN) for short-term forecasting of transit passenger flow[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(10): 18155-18174.
- [12] Wu Z H, Pan S R, Long G D, et al. Graph WaveNet for deep spatial-temporal graph modeling[C]//Proceedings of the 28th International Joint Conference on Artificial Intelligence. Macao, 2019: 1907-1913.
- [13] Li Y G, Yu R, Shahabi C, et al. Diffusion convolutional recurrent neural network: data-driven traffic forecasting[C]//International Conference on Learning Representations. Toulon, 2017: 1-16.
- [14] Xu Y W, Liu M C. GPT4TFP: Spatio-temporal fusion large language model for traffic flow prediction[J]. Neurocomputing, 2025, 625: 129562.
- [15] Zhou T, Niu P S, Wang X, et al. One fits all: power general time series analysis by pretrained LM[C]//Advances in Neural Information Processing Systems. New Orleans, 2023: 43322-43355.
- [16] Liu C X, Xu Q X, Miao H, et al. TimeCMA: towards LLM-empowered multivariate time series forecasting via cross-modality alignment[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2025, 39(18): 18780-18788.
- [17] Liu X, Hu J F, Li Y, et al. UniTime: a language-empowered unified model for cross-domain time series forecasting[C]//Proceedings of the ACM Web Conference. Singapore, 2024: 4095-4106.

- [18] Jin M, Pan S R, Li Y F, et al. TimeLLM: time series forecasting by reprogramming large language models[M]//AI for Time Series. Boca Raton: CRC Press, 2026: 123-150.
- [19] Liu C X, Yang S, Xu Q X, et al. Spatial-temporal large language model for traffic prediction[C]//2024 25th IEEE International Conference on Mobile Data Management. Piscataway, 2024: 31-40.
- [20] Chen X Y, Sun L J. Bayesian temporal factorization for multidimensional time series prediction[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(9): 4659-4673.
- [21] Xie R H, Zhang H N, Li H T, et al. High-speed rail passenger flow prediction based on crossformer and quantile regression: a deep learning approach assisted by Internet search indices[J]. Measurement, 2025, 242: 116189.
- [22] Mallick T, Macfarlane J, Balaprakash P. Uncertainty quantification for traffic forecasting using deep-ensemble-based spatiotemporal graph neural networks[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(8): 9141-9152.
- [23] Tashiro Y, Song J M, Song Y, et al. CSDI: conditional score-based diffusion models for probabilistic time series imputation[EB/OL]. (2021-10-27)[2026-05-30]. <https://arxiv.org/abs/2107.03502>.
- [24] 张金雷. 城市轨道交通网短时客流预测方法研究[D]. 北京: 北京交通大学, 2021.
- Zhang Jinlei. Study of the Short-term Passenger Flow Prediction in Urban Rail Transit Networks[D]. Beijing: Beijing Jiaotong University, 2021.
- [25] Liu Y, Liu Z Y, Jia R. DeepPF: a deep learning based architecture for metro passenger flow prediction[J]. Transportation Research Part C: Emerging Technologies, 2019, 101: 18-34.
- [26] Zhang J L, Chen F, Cui Z Y, et al. Deep learning architecture for short-term passenger flow forecasting in urban rail transit[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(11): 7004-7014.
- [27] Noursalehi P, Koutsopoulos H N, Zhao J H. Real time transit demand prediction capturing station interactions and impact of special events[J]. Transportation Research Part C: Emerging Technologies, 2018, 97: 277-300.
- [28] 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): 194-204.
- 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): 194-204.
- [29] 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): 3557-3568.
- 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): 3557-3568.
- [30] 王金水, 欧雪雯, 陈俊岩, 等. 基于时空超图卷积模型的城市轨道站点客流预测[J]. 铁道科学与工程学报, 2023, 20(12): 4506-4516.
- Wang Jinshui, OU Xuewen, Chen Junyan, et al. Passenger flow forecast of urban rail transit stations based on spatio-temporal hypergraph convolution model[J]. Journal of Railway Science and Engineering, 2023, 20(12): 4506-4516.
- [31] Li P, Wang S, Zhao H T, et al. IG-net: an interaction graph network model for metro passenger flow forecasting[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(4): 4147-4157.
- [32] Gao C, Liu H, Huang J J, et al. Regularized spatial-temporal graph convolutional networks for metro passenger flow prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(9): 11241-11255.
- [33] Wang J C, Zhang Y, Wei Y, et al. Metro passenger flow prediction via dynamic hypergraph convolution networks[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(12): 7891-7903.
- [34] 惠阳, 王永岗, 彭辉, 等. 基于优化 PSO-BP 算法的耦合时空特征下地铁客流预测[J]. 交通运输工程学报, 2021, 21(4): 210-222.
- Hui Yang, Wang Yonggang, Peng Hui, et al. Subway passenger flow prediction based on optimized PSO-BP algorithm with coupled spatial-temporal characteristics[J]. Journal of Traffic and Transportation Engineering, 2021, 21(4): 210-222.
- [35] 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): 2042-2048.
- 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.
- [36] 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): 1-6.
- 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): 1-6.
- [37] Ni M, He Q, Gao J. Forecasting the subway passenger flow under event occurrences with social media[J]. IEEE Transactions on Intelligent Transportation Systems, 2017, 18(6): 1623-1632.
- [38] Zhang S X, Zhang J L, Yang L X, et al. COV-STFormer for short-term passenger flow prediction during COVID-19 in urban rail transit systems[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(5): 3793-3811.
- [39] Xue G, Liu S F, Ren L, et al. Forecasting the subway passenger flow under event occurrences with multivariate disturbances[J]. Expert Systems with Applications, 2022, 188: 116057.

- [40] Zhang S X, Zhang J L, Yang L X, et al. Physics guided deep learning-based model for short-term origin-destination demand prediction in urban rail transit systems under pandemic[J]. Engineering, 2024, 41: 276-296.
- [41] Liu L B, Zhu Y Y, Li G B, et al. Online metro origin-destination prediction via heterogeneous information aggregation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(3): 3574-3589.
- [42] Noursalehi P, Koutsopoulos H N, ZHAO J H. Dynamic origin-destination prediction in urban rail systems: a multi-resolution spatio-temporal deep learning approach[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(6): 5106-5115.
- [43] Zhuang D Y, Wang S H, Koutsopoulos H, et al. Uncertainty quantification of sparse travel demand prediction with spatial-temporal graph neural networks[C]//Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. Washington DC, 2022: 4639-4647.
- [44] Zhang Y, Sun K Y, Wen D, et al. Deep learning for metro short-term origin-destination passenger flow forecasting considering section capacity utilization ratio[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(8): 7943-7960.
- [45] Chu K F, Lam A Y S, Li V O K. Deep multi-scale convolutional LSTM network for travel demand and origin-destination predictions[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(8): 3219-3232.
- [46] Ke J T, Qin X R, Yang H, et al. Predicting origin-destination ride-sourcing demand with a spatio-temporal encoder-decoder residual multi-graph convolutional network[J]. Transportation Research Part C: Emerging Technologies, 2021, 122: 102858.
- [47] 申慧涛, 郑亮, 李树凯, 等. 基于生成对抗网络的地铁 OD 需求短时预测[J]. 铁道科学与工程学报, 2022, 19(6): 1530-1539.
Shen Huitao, Zheng Liang, Li Shukai, et al. Short-term urban metro OD demand prediction with a Generative Adversarial Network[J]. Journal of Railway Science and Engineering, 2022, 19(6): 1530-1539.
- [48] 陈鹤林, 陈军华, 高天泽. 模型融合时空特征的 GRU-双层 Transformer 轨道交通 OD 客流预测[J/OL]. 铁道科学与工程学报, 2025. DOI: 10.19713/j.cnki.43-1423/u.T20251332.
Chen Helin, Chen Junhua, Gao Tianze. A GRU-double-layer Transformer model for metro OD flow prediction with integrated spatiotemporal features[J/OL]. Journal of Railway Science and Engineering, 2025. DOI: 10.19713/j.cnki.43-1423/u.T20251332.
- [49] 苏焕银, 沈金聪, 莫尚霖, 等. 融合时空高维特征的城市轨道交通 OD 客流预测[J/OL]. 铁道科学与工程学报, 2026. DOI: 10.19713/j.cnki.43-1423/u.T20251934.
Su Huanyin, Shen Jincong, Mo Shanglin, et al. Origin-destination passenger flow prediction in urban rail transit systems fusing high-dimensional spatio-temporal features[J/OL]. Journal of Railway Science and Engineering, 2026. DOI: 10.19713/j.cnki.43-1423/u.T20251934.
- [50] Wang M, Zhang Y, Zhao X, et al. Traffic origin-destination demand prediction via multichannel hypergraph convolutional networks[J]. IEEE Transactions on Computational Social Systems, 2024, 11(4): 5496-5509.
- [51] Liu Y, Chen B L, Zheng Y S, et al. ODMixer: fine-grained spatial-temporal MLP for metro origin-destination prediction[J]. IEEE Transactions on Knowledge and Data Engineering, 2025, 37(9): 5508-5522.
- [52] Zou L M, Wang Z J, Guo R. Real-time prediction of transit origin-destination flows during underground incidents[J]. Transportation Research Part C: Emerging Technologies, 2024, 163: 104622.
- [53] 林湛, 蒋明青, 刘剑锋, 等. 城市轨道交通客流分配的改进 Logit 模型及方法[J]. 交通运输系统工程与信息, 2012, 12(6): 145-151.
Lin Zhan, Jiang Mingqing, Liu Jianfeng, et al. Improved logit model and method for urban rail transit network assignment[J]. Journal of Transportation Systems Engineering and Information Technology, 2012, 12(6): 145-151.
- [54] 陈培文. 基于改进 Logit 模型的城市轨道交通客流分配方法研究[D]. 北京: 北京交通大学, 2018.
Chen Peiwen. Study on passenger flow assignment method of urban rail transit based on improved Logit model[D]. Beijing: Beijing Jiaotong University, 2018.
- [55] 费爽. 基于乘客对路网熟悉程度的城市轨道交通客流分配研究[D]. 北京: 北京交通大学, 2019.
Fei Shuang. Research on passenger flow assignment of urban rail transit based on passengers' familiarity with rail transit network[D]. Beijing: Beijing Jiaotong University, 2019.
- [56] 何明, 左静, 余召. 考虑多属性因素融合的城市轨道交通短时断面客流预测[J]. 深圳大学学报(理工版), 2025, 42(6): 723-732.
He Ming, Zuo Jing, Yu Zhao. Short-term cross-sectional passenger-flow forecasting for urban rail transit with multi-attribute feature fusion[J]. Journal of Shenzhen University (Science and Engineering), 2025, 42(6): 723-732.
- [57] 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(自然科学版), 2022, 36(6): 164-171.
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 Institute of Technology, 2022, 36(6): 164-171. (in Chinese)
- [58] 曹凯鑫. 基于深度学习的轨道交通断面客流短时预测[D]. 南京: 东南大学, 2019.
Cao Kaixin. Short-term prediction of section passenger flow of urban rail transit based on deep learning[D]. Nanjing: Southeast University, 2019.
- [59] Zhang J L, Chen F, Yang L X, et al. Network-wide link

- travel time and station waiting time estimation using automatic fare collection data: a computational graph approach[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(11): 21034-21049.
- [60] Zhang Y, Yang Q. A survey on multi-task learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 34(12): 5586-5609.
- [61] Zhao L, Zou L M, Wang Z J, et al. Multi-task graph-based model for metro flow prediction under dynamic urban conditions[J]. Computer-Aided Civil and Infrastructure Engineering, 2025, 40(21): 3239-3258.
- [62] Qiu H, Zhang J L, Yang L X, et al. Spatial-temporal multi-task learning for short-term passenger inflow and outflow prediction on holidays in urban rail transit systems[EB/OL]. (2025-01-18)[2026-05-30]. <https://doi.org/10.1007/s11116-025-10583-z>.
- [63] 杨静, 侯宇晴, 谢余晨, 等. 城市轨道交通网络短时OD客流多任务协同预测[J]. 交通运输系统工程与信息, 2025, 25(5): 261-270.
Yang Jing, Hou Yuqing, Xie Yuchen, et al. Multi-task cooperative prediction of short-term origin-destination flows in urban rail transit networks[J]. Journal of Transportation Systems Engineering and Information Technology, 2025, 25(5): 261-270.
- [64] 沈恬. 基于多任务学习的短时地铁客流预测方法研究[D]. 金华: 浙江师范大学, 2025.
Shen Tian. Research on short-term metro passenger flow prediction methods based on multi-task learning[D]. Jinhua: Zhejiang Normal University, 2025.
- [65] Yang Y J, Zhang J L, Yang L X, et al. Short-term passenger flow prediction for multi-traffic modes: a Transformer and residual network based multi-task learning method[J]. Information Sciences, 2023, 642: 119144.
- [66] Zhang J L, Yang Y J, Yang L X, et al. Joint short-term origin-destination demand prediction for multimodal transport systems[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2026, 48(3): 2458-2475.
- [67] Li Q, Zheng Z C, Luo C Y, et al. Joint prediction and understanding of multimodal traffic flow with a bidirectional temporal dynamic spatial hypergraph neural network model[J]. Transportation Research Part C: Emerging Technologies, 2025, 180: 105358.
- [68] Yang X, Ling J H, Gong S M, et al. Multi-scale spatio-temporal-enhanced network for multimodal traffic flow joint prediction[EB/OL]. (2026-04-27)[2026-05-30]. <https://ieeexplore.ieee.org/document/11495034>.
- [69] 江丽英. 基于图卷积网络和多任务学习的交通需求预测方法研究[D]. 厦门: 厦门大学, 2022.
Jiang Liying. Research on traffic demand prediction based on graph neural network and multi-task learning[D]. Xiamen: Xiamen University, 2022.
- [70] 吴媚. 基于时空异质解耦方法的多模式交通流预测[D]. 杭州: 杭州电子科技大学, 2025.
- Wu Mei. Multi-mode traffic flow prediction based on spatio-temporal heterogeneity decoupling method[D]. Hangzhou: Hangzhou Dianzi University, 2025.
- [71] 韩浩东, 陈盛双, 谢良. 基于超图的多任务注意力交通流预测模型[J]. 武汉理工大学学报, 2023, 45(10): 150-159.
Han Haodong, Chen Shengshuang, Xie Liang. A multitask attention traffic flow prediction model based on hypergraph[J]. Journal of Wuhan University of Technology, 2023, 45(10): 150-159.
- [72] Chen C, Oliveira G, Noghabi H S, et al. LLM-TS integrator: integrating LLM for enhanced time series modeling[EB/OL]. (2024-10-21)[2026-05-30]. <https://arxiv.org/abs/2410.16489>.
- [73] Liu Q X, Liu X, Liu C H, et al. Time-FFM: towards LM-empowered federated foundation model for time series forecasting[C]//Advances in Neural Information Processing Systems. Vancouver, 2024: 94512-94538.
- [74] 郭旷, 王雪梅, 张宁. 城市轨道交通短时客流不确定性预测模型[J]. 城市轨道交通研究, 2020, 23(1): 22-26.
Guo Kuang, Wang Xuemei, Zhang Ning. Uncertainty prediction model of short-term passenger flow in urban rail transit[J]. Urban Mass Transit, 2020, 23(1): 22-26.
- [75] Tang J B, Xia L H, Huang C. Explainable spatio-temporal graph neural networks[C]//Proceedings of the 32nd ACM International Conference on Information and Knowledge Management. Birmingham United Kingdom, 2023: 2432-2441.
- [76] Elmachet A N, Grigas P. Smart “predict, then optimize”[J]. Management Science, 2022, 68(1): 9-26.
- [77] Li R, Zhang H P, Sun M Y, et al. Decision-oriented learning for future power system decision-making under uncertainty[EB/OL]. (2024-01-08)[2026-05-30]. <https://arxiv.org/abs/2401.03680>.
- [78] Qi M, Shi Y Y, Qi Y Z, et al. A practical end-to-end inventory management model with deep learning[J]. Management Science, 2023, 69(2): 759-773.
- [79] Tian X C, Yan R, Liu Y, et al. A smart predict-then-optimize method for targeted and cost-effective maritime transportation[J]. Transportation Research Part B: Methodological, 2023, 172: 32-52.
- [80] Ha D, Schmidhuber J. World models[EB/OL]. (2018-03-27)[2026-05-30]. <https://arxiv.org/abs/1803.10122>.
- [81] Zhang Z J, Liniger A, Dai D X, et al. TrafficBots: towards world models for autonomous driving simulation and motion prediction[C]//2023 IEEE International Conference on Robotics and Automation (ICRA). London, 2023: 1522-1529.
- [82] Pourkeshavatz M, Liu T R, Rhinehart N. AutoWorld: scaling multi-agent traffic simulation with self-supervised world models[EB/OL]. (2026-03-30)[2026-05-30]. <https://arxiv.org/abs/2603.28963>.

(编辑: 王艳菊)