



计算机科学

COMPUTER SCIENCE

基于智联电动车流量生成的跨区域换电站部署算法

陈佳怡, 顾丞毅, 周继华, 赵涛, 王双超, 朱明星, 向朝参

引用本文

陈佳怡, 顾丞毅, 周继华, 赵涛, 王双超, 朱明星, 向朝参. [基于智联电动车流量生成的跨区域换电站部署算法](#)[J]. 计算机科学, 2025, 52(12): 71-80.

CHEN Jiayi, GU Chengyi, ZHOU Jihua, ZHAO Tao, WANG Shuangchao, ZHU Mingxing, XIANG Chaocan. [Cross-regional Battery Swapping Station Deployment Algorithm Based on Intelligent E-scooterFlow Generation](#) [J]. Computer Science, 2025, 52(12): 71-80.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[生成扩散模型研究综述](#)

Survey on Generative Diffusion Model

计算机科学, 2024, 51(1): 273-283. <https://doi.org/10.11896/jsjcx.230300057>

[空地协同移动群智感知研究综述](#)

Review of Mobile Air-Ground Crowdsensing

计算机科学, 2022, 49(11): 242-249. <https://doi.org/10.11896/jsjcx.220400264>

[大数据驱动的社会经济地位分析研究综述](#)

Big Data-driven Based Socioeconomic Status Analysis:A Survey

计算机科学, 2022, 49(4): 80-87. <https://doi.org/10.11896/jsjcx.211100014>

[带宽和时延受限的流媒体服务器集群负载均衡机制](#)

Load Balancing Mechanism for Bandwidth and Time-delay Constrained Streaming Media Server Cluster

计算机科学, 2021, 48(6): 261-267. <https://doi.org/10.11896/jsjcx.200400131>

[基于聚类簇中心的共识跨链交换模型](#)

Accross Block Chain Consensus Transation Model Based on Cluster Center

计算机科学, 2019, 46(11A): 557-561.

基于智联电动车流量生成的跨区域换电站部署算法

陈佳怡¹ 顾丞毅¹ 周继华² 赵涛^{2,3} 王双超⁴ 朱明星⁵ 向朝参¹

1 重庆大学计算机学院 重庆 401331

2 西南大学计算机与信息科学学院软件学院 重庆 400715

3 重庆大学微电子与通信工程学院 重庆 401331

4 中移物联网有限公司 重庆 401121

5 航天新通科技有限公司 重庆 401332

(jiayichen@stu.cqu.edu.cn)

摘要 随着换电模式的兴起,以智联电动车为主要交通工具的短途出行方式变得越来越流行,这促使提供换电服务的公司在城市中不断扩张业务规模。扩张时,公司倾向于在用户活跃度较高的区域设置换电站,活跃度水平可以通过智联电动车区域流量来体现。然而,在实际部署换电站之前,新区域的运营数据缺乏,使得依赖历史数据进行部署优化的数据驱动方法难以发挥作用,形成“数据缺失—难以部署—无法获取数据”的循环困境。对此,提出了一种基于智联电动车流量生成的跨区域换电站部署算法。首先,构建基于去噪扩散概率模型的区域流量生成模型,捕捉区域流量时空特征,利用已部署区域的数据来生成待部署区域的数据。然后,将区域流量纳入换电站部署问题,构建最大化换电站部署效益的优化模型。最后,基于自适应遗传特性做出跨区域换电站部署决策。基于四川省成都市真实换电数据集对所提算法进行了性能评估,实验结果验证了所提解决方案的有效性。

关键词: 换电模式;换电站部署;区域流量;去噪扩散概率模型

中图分类号 TP393

Cross-regional Battery Swapping Station Deployment Algorithm Based on Intelligent E-scooter Flow Generation

CHEN Jiayi¹, GU Chengyi¹, ZHOU Jihua², ZHAO Tao^{2,3}, WANG Shuangchao⁴, ZHU Mingxing⁵ and XIANG Chaocan¹

1 College of Computer Science, Chongqing University, Chongqing 401331, China

2 School of Software, College of Computer and Information Science, Southwest University, Chongqing 400715, China

3 School of Microelectronics and Communication Engineering, Chongqing University, Chongqing 401331, China

4 China Mobile IOT Company Limited, Chongqing 401121, China

5 Aerospace New Generation Communications Company Limited, Chongqing 401332, China

Abstract Battery swapping services are becoming increasingly popular as intelligent E-scooters emerge as a primary mode of short-distance transportation. As a result, companies providing battery swapping services are expanding their operations in urban regions. During expansion, companies prioritize deploying battery swapping stations in regions with higher user activity, as indicated by intelligent E-scooter flow. However, the lack of operational data in new regions makes data-driven deployment optimization approaches less effective, creating a dilemma of “data scarcity-deployment difficulty-lack of data acquisition”. To address this issue, this paper proposes a cross-regional battery swapping station deployment algorithm based on intelligent E-scooter flow generation. Firstly, a regional flow generation model based on a denoising diffusion probabilistic model is constructed to capture the spatiotemporal characteristics of flow and generate synthetic flow data for target regions using data from already deployed regions. Then, the generated flow is incorporated into a deployment optimization problem, modeled to maximize the overall benefit of station deployment. Finally, a cross-regional deployment strategy is derived using an adaptive genetic algorithm. The proposed algorithm is evaluated using a real-world dataset from Chengdu, Sichuan Province. Experimental results demonstrate the effectiveness of the proposed solution.

Keywords Battery swapping model, Battery swapping station deployment, Regional flow, Denoising diffusion probabilistic model

1 引言

智联电动车因具有快捷方便、绿色环保的特性,逐渐成为人们短途出行的重要交通工具。在 2023 年底前,中国的智联电动车市场保有量已达 3.5 亿辆^[1]。然而,传统的智联电动车的充电方式因充电时间长、充电地点不规范等原因存在严重的消防安全问题^[2]。因此,创新的电池共享换电模式应运而生,该模式通过“以换代充”实现快速、安全的补能^[3]。近年来,换电行业进入快速发展期,例如,Gogoro 已部署 2 626 个换电站,每月平均增加 12 000 个电池^[4]。这促使提供换电服务的公司向城市的新区域扩张换电业务。随着部署范围的扩张,跨区域部署逐渐成为常态。

相较于依赖人工经验的换电站部署方法,基于数据驱动的方法在准确性与泛化能力方面更具优势。例如,针对与换电站部署密切相关的电动车区域流量数据,可以通过挖掘历史数据来反映用户活跃度,并据此构建优化模型。然而,在跨区域部署场景下,待部署区域通常缺乏运营数据,使得依赖历史数据进行部署优化的数据驱动方法难以发挥作用,形成“数据缺失—难以部署—无法获取数据”的循环困境^[5]。

近年来,生成模型的飞速发展引起了广泛关注。其中,去噪扩散概率模型已经在多个研究方向取得了显著成果,包括计算机视觉^[6-7]、自然语言处理^[8-9]、时间序列^[10-11]、音频处理^[12-13]和图形生成^[14-15]等。去噪扩散概率模型具备强大的生成能力,可以通过学习已部署区域的流量分布模式,在待部署区域实现流量数据的模拟生成,为数据驱动的换电站部署方法提供基础。这一技术为解决换电站部署的循环困境提供了新的可能。然而,换电站部署仍然面临以下两大核心挑战。

1) 智联电动车区域流量的生成具有高度复杂性。换电公司在城市的部分区域部署了换电站,并通过硬件设备存储了流量数据^[16]。这些数据虽然可用于分析已部署区域的流量模式,但区域流量受用户行为、换电环境特征等多方面因素影响,使得构建用于跨区域换电站部署的生成模型面临挑战。

2) 换电站部署问题为大规模组合优化问题。换电站部署不仅需兼顾区域流量与换电站数量之间的匹配程度,还需考虑换电站网络的服务覆盖范围等。该问题解空间庞大,并具备 NP-hard 特性,无法在多项式时间内找到该问题的最优解。因此,在合理的计算时间内高效寻求近似最优的部署方案具有挑战。

为了应对上述问题和挑战,本文提出了一种基于智联电动车流量生成的跨区域换电站部署算法。针对智联电动车区域流量生成的复杂性这一挑战,深入分析已部署换电站区域的历史流量数据,构建基于去噪扩散概率模型的电动车区域流量生成模型。该模型设计了结合图卷积网络空间子模块和 Transformer layer 时间子模块的去噪网络,能够有效捕捉区域流量的复杂时空特性。同时,为了量化和模拟换电环境对区域流量的影响,构建了换电知识图谱来引导空间模块与时间模块的有效融合,提高流量生成的准确性。针对换电站部署的大规模组合优化问题,本文建立了数学优化模型,并证明它是 NP-hard 问题。为了在多项式时间内得到结果,进一步设计基于自适应遗传算法的优化方法。该方法能够在可接受的计算时间内优化部署方案,实现流量

生成与站点布局的协同优化。

综上所述,本文主要有以下 3 方面的创新:

1) 基于成都市真实换电数据集,对智联电动车区域流量的特征和影响因素进行了分析,为提高生成模型的准确性奠定了基础;

2) 提出了基于智联电动车流量生成的跨区域换电站部署算法,设计了基于区域流量生成的评估机制,实现换电站部署方案的效益最大化;

3) 基于真实数据集进行实验验证,结果表明,本文方法在流量生成和站点优化方面均优于传统方法,有效提升了部署决策质量。

本文第 2 章介绍国内外相关工作研究;第 3 章详细介绍基于智联电动车流量生成的跨区域换电站部署算法框架;第 4 章展示实验结果;最后总结全文并展望未来。

2 相关工作

近年来,随着智联电动车绿色节能优势的显现与市场的快速扩大,相关问题受到广泛关注。针对智联电动车充/换电站,对用户进行换电站个性化推荐^[3]、换电站电池充电调度^[17]、充/换电站的部署规划问题等的研究越来越多。其中,部署规划问题的研究主要分为两个方向。

一部分研究基于大量、多源的历史数据。例如,Xiong 等^[18]基于用户的战略性充电行为、交通状况和排队等待时间等数据,提出了一种充电站选址的双层优化模型。Li 等^[19]基于电动车轨迹数据和现有的充电站数据,最小化用户找到充电站的平均时间以及缩短充电点的平均等待时间。Du 等^[20]基于历史充电需求数据,规划充电站的建设点和每个充电站的充电桩数量,使 POI 覆盖范围与区域充电需求之间达到最佳平衡。Von Wahl 等^[21]利用充电需求、充电概率等数据,最大限度地缩短排队等待、行驶和充电的总时间。Bae 等^[22]基于用户历史数据,考虑用户在选择充电站位置时的拥挤度和个人偏好,并通过去中心化博弈论决策算法和 K-means 聚类算法来解决选址问题。这些工作在充/换电站部署规划中依赖大量的历史数据。然而,这些数据通常是已部署充/换电站网络运行后的结果,无法直接用于未部署区域的规划决策。现有工作普遍忽略了换电站在实际部署前缺乏历史数据的问题。与现有研究不同,本文针对换电站的跨区域部署场景,提出了一种基于智联电动车区域流量生成的优化模型,以解决历史数据缺失的问题。

另一部分研究聚焦于无历史数据情况下获取部署问题中涉及到的城市数据。在部署问题场景下,典型的城市数据包括用户需求数据、用户轨迹数据等。Wang 等^[23]提出跨城市深度时空预测学习方法,迁移源城市学习到的知识并找到具有相似模式的跨城市匹配区域,预测目标城市中某些类型的服务数据。Wang 等^[5]从多源数据中提取特征,设计基于注意力的时空城市域自适应网络,实现跨城市的用户需求预测,从而确定目标城市充电站的位置和慢速/快速充电器的数量。Zhang 等^[24]提出了一种自适应的深度迁移学习框架,其通过城市知识图生成城市规模的蜂窝流量,实现跨城市的 5G 基站部署研究。Rong 等^[25]提出了一种基于图去噪扩散的方法,以学习 OD 网络中节点与边的条件联合概率分布,从而实

现城市级 OD 网络的生成。Li 等^[26]提出基于注意力机制的双头时空生成对抗网络,以实现多步人群流量的模拟。与这些现有工作不同,本文在换电站部署优化过程中引入了区域流量因素,以提升部署方案的合理性和可信度。

3 基于智联电动车流量生成的跨区域换电站部署算法

为满足换电站在城市中的扩张需求,本文提出基于智联电动车流量生成的跨区域换电站部署算法。如图 1 所示,该算法包括基于去噪扩散概率模型的智联电动车区域流量生成和基于自适应遗传特性的换电站部署优化问题求解两个模块。基于去噪扩散概率模型的智联电动车区域流量生成模块针对真实换电数据集,分析区域流量数据的特征。根据分析结果,构建生成模型,利用已部署区域的历史数据对其进行训练,并将模型应用到待部署区域。基于自适应遗传特性的换电站部署优化问题求解模块首先构建换电站部署的优化问题,实现换电站数量与区域流量之间的相关性和换电站网络服务覆盖范围的综合最大化,然后基于自适应遗传特性对大规模组合优化问题进行求解。

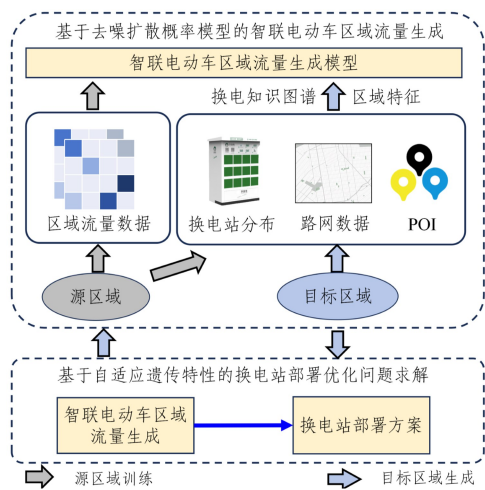


图 1 算法架构图

Fig.1 Algorithm architecture

3.1 基于去噪扩散概率模型的智联电动车区域流量生成

3.1.1 智联电动车区域流量分析

一个典型的换电系统如图 2 所示。换电公司在城市中部部署换电站,用户到达换电站,将车上的低电量电池与换电柜中的高电量电池进行交换。电池管理系统(BMS)会将电池的相关数据传输到换电服务提供商的服务器端。本文数据集来自成都市的一家换电公司,数据详情如下。

1) 电池状态数据:包括电池的唯一 ID、电池工况数据、数据时间戳以及电池的 GPS 定位信息等。电池的 GPS 数据更新频率为每 15 min 一次,提供了电池在特定时间点的精确地理位置,有助于分析电池的使用和流动趋势。

2) 换电交易数据:包括唯一的换电交易 ID、用户 ID、交易时间戳、换电站的具体位置以及换入和换出的电池 ID 等信息。每次换电交易完成后,相关数据会实时记录。

3) 换电站数据:包括换电站的唯一 ID、地理位置、建造时间戳等。

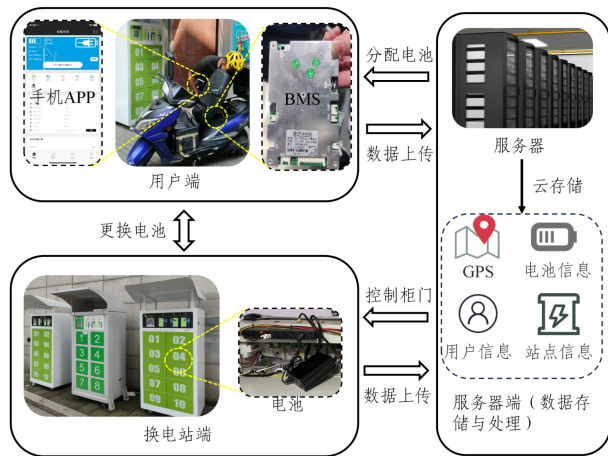


图 2 换电系统

Fig.2 Battery swapping system

基于路网划分的区域边界数据及电池的 GPS 位置数据,统计每个区域在每个小时内进入和离开的电池数量,并取二者的均值作为该时段的流量值,以此衡量每个区域不同时段的用户活跃度。之后分析流量的数据特征,具体如下。

1) 不同区域的流量规模差异悬殊。图 3 可视化了成都市不同区域平均每天的电动车流量大小。可以看出,主要商业区等区域的流量高度集中,形成了明显的流量热点区域。相比之下,外围区域和部分非核心城区的流量较低。进一步地,对每个区域的特征均进行标准化,再分析哪些区域内的特征与流量大小密切相关。如表 1 所列,区域流量大小与换电站的数量和位置密切相关。换电站数量较多的区域,能够为用户提供更便捷的换电服务,从而吸引更多用户前往该区域,进而增加区域流量。同时,区域流量大小还与 POI 的密度和种类相关。例如,公司 POI 密度大的区域,通常意味着有更多的潜在用户、更多的商业活动和更高的消费能力。

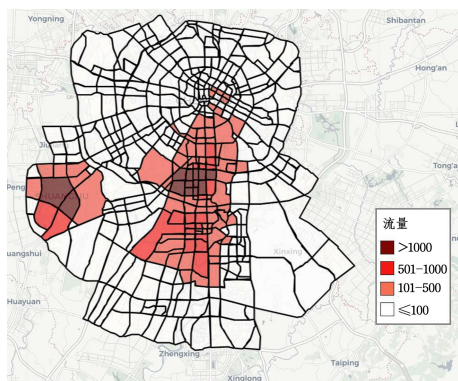


图 3 成都市智联电动车流量的空间分布

Fig.3 Spatial distribution of intelligent E-scooter flow volume in Chengdu

表 1 皮尔森相关系数排名前五的区域特征

Table 1 Top five features with highest Pearson coefficients

特征	皮尔森指数
邻近区域内的换电站数量	0.7151
邻接区域内的换电站数量	0.6971
区域内的换电站数量	0.4837
邻近区域公司 POI 密度	0.3489
邻接区域公司 POI 密度	0.3254

2)从时间分布上看,区域流量表现出用户行为驱动的规律性。换电服务的用户群体主要是频繁使用智能电动车的即时配送员^[27]。因此,区域流量时间分布与人们点外卖的行为模式密切相关。如图4(a)所示,流量集中在白天,且一天有两个高峰,分别是中午12-13点及晚上18-19点。中午12-13点是最高峰,同时也是人们点外卖的高峰时间。如图4(b)所示,周分布与日分布相似,日均流量分布呈现出相同的高峰时段,表明这种时间分布规律具有稳定性和周期性。

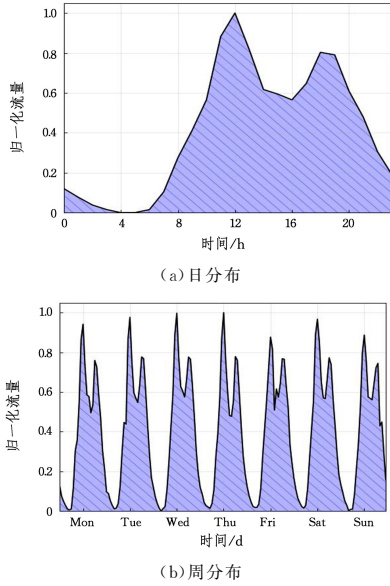


图4 不同时间尺度下区域流量的时间分布

Fig. 4 Temporal distribution at different time scales

3)区域流量存在复杂的时空特性。一方面,区域流量受到临近区域的影响,呈现出空间上的依赖性;另一方面,具有相似城市功能的区域流量表现出相似的时间模式,这表明区域流量还受到环境的显著影响。图5(a)、图5(b)分别表示办公区的流量日模式和周模式。




图5 办公区不同时间尺度下区域流量的时间分布

Fig. 5 Temporal distribution in office regions at different time scales

图6(a)、图6(b)分别表示住宅区的流量日模式和周模式。在办公区,午高峰和晚高峰流量的比值更高,表明人们倾向在工作日中午点餐。与办公区相比,居民区早晨和晚上点外卖的人数比值更高。从周分布来看,不同功能区的周末流量与工作日流量之间存在显著差异,办公区的周末流量明显低于工作日流量,而住宅区则呈现相反的趋势。




图6 住宅区不同时间尺度下区域流量的时间分布

Fig. 6 Temporal distribution in residential regions at different time scales

3.1.2 智能电动车区域流量生成模型

智能电动车区域流量生成模型的结构^[28]紧密结合了3.1.1节中阐述的生成数据的特征。模型的详细介绍如下。

1)去噪扩散概率模型(Denoising Diffusion Probabilistic Model, DDPM)

智能电动车区域流量生成模型以DDPM为基础,包括两个相互关联的过程^[29]:一个预定义的正向过程,通过添加噪声 ϵ 将原始数据 x_0 映射到一个更简单的分布(标准正态分布);一个去噪推断的反向过程,该过程利用去噪网络预测出噪声 $\hat{\epsilon}$,逆转正向过程的影响,从标准正态分布中还原出数据。在本文场景下,利用DDPM生成流量 $flow \in \mathbb{R}^{D \times N \times T}$,其中 D 代表生成的天数, N 代表区域的数量, T 表示流量的时间间隔数。具体如图7所示。




图7 基于DDPM的生成过程

Fig. 7 Generation process based on DDPM

2) 流量先验网络

基本的去噪扩散概率模型将数据分布统一映射到标准正态分布。然而,不同区域的流量规模差异悬殊,多区域流量统一压缩到单一标准正态分布,会导致区域特异性信息丢失。因此,流量先验网络 f_θ 利用区域特征向量提前估算电动车区域流量均值 $\hat{\mu}_r \in \mathbb{R}^{D \times N \times T}$, 并将其作为正向过程中要映射的高斯分布的均值,以此来区分不同的区域^[28,30]。此时,去噪扩散概率模型将数据分布映射到 $(\hat{\mu}_r, I)$ 。 f_θ 由一个3层前馈神经网络构成,损失函数采用 \mathcal{L}_2 。

3) 换电知识图谱

为了更好地解析区域流量复杂的时空特性,构建换电知识图谱来仿真换电服务的城市环境,并抓取实体之间的关系^[31]。换电知识图谱的结构如图8所示,其由7种事实组成,表示了区域之间直接接壤、不接壤但邻近、具有相似功能属性3类关系,表明了POI所属区域和类别。同时,由于待部署区域尚未实际运行换电站网络并缺乏直接的换电站信息,在构建换电知识图谱时,引入了部分来自其他同类型企业的公开信息,以更全面地模拟换电服务环境。

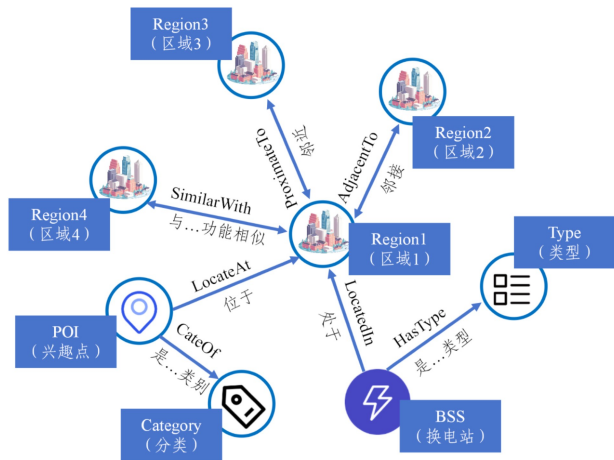


图8 换电知识图谱结构

Fig. 8 Structure of battery swapping knowledge graph

4) 语义驱动的时空融合感知模块

该模块采用由空间子模块关系型图卷积网络与时间子模块 Transformer layer 组成的双分支结构。进一步地,引入换电知识图谱嵌入,经过 TuckER^[32] 转换后用于注意力机制,作为 Query 指导空间子模块和空间子模块的融合过程。

去噪网络整体结构基于 DiffWave^[33], 其中区域特征向量作为条件模块的输入,语义驱动的时空融合感知模块替换双向扩张卷积神经网络。

3.2 基于自适应遗传特性的换电站部署优化问题求解

根据3.1节得到智联电动车区域流量生成模型后,将模型用于实际换电站部署优化。为此,本文建立换电站部署的优化模型,旨在最大化换电站数量与区域流量之间的相关性以及换电站网络的服务覆盖范围。随后,使用自适应遗传算法来解决这个大规模组合优化问题。

3.2.1 换电站部署优化问题建模

定义1(区域) 基于公开路网数据,城市被划分成彼此独立的 I 个区域。进一步地, $R = \{r_1, r_2, \dots, r_I\}$ 表示城市的

所有区域的集合, $R_{TR} = \{r_1, r_2, \dots, r_m\} \in R$ 表示 m 个等待部署换电站的目标区域, $R_{SR} = \{r_{m+1}, r_{m+2}, \dots, r_I\} \in R$ 表示剩余的已经部署了换电站的源区域。

定义2(电动车区域流量) $\mathbf{F}_i = [f_i^1, f_i^2, \dots, f_i^T]$ 代表第 i 个区域一天的流量向量。其中,一天被划分为 T 个时间间隔,所有间隔的集合表示为 $\mathcal{T} = \{1, \dots, t, \dots, T\}$; f_i^t 代表在一天中第 t 个时间间隔内的电动车区域流量大小,反映了第 i 个区域在第 t 个时段内的用户活跃度水平。

定义3(换电站) 假设等待部署的换电站的数量为 J , 元组 $\omega_j = (g_j, e_j)$ 代表第 j 个换电站。其中, $g_j \in R_{TR}$ 代表换电站的位置, e_j 代表换电站的部署成本。特别地, e_j 由3部分组成:

$$e_j = l_j + bss_j + m_j \quad (1)$$

其中, l_j 为土地成本, bss_j 为购买换电站及电池的成本, m_j 为后期维护成本。

定义4(换电站部署方案) 矩阵 $\mathbf{X} = [x_{ij}]_{I \times J}$ 代表换电站部署方案,其中变量 x_{ij} 代表第 j 个换电站是否部署在了第 i 个区域, $x_{ij} = 1$ 代表部署, $x_{ij} = 0$ 代表未部署。为方便起见, \mathbf{X}_{TR} 代表目标区域 R_{TR} 的部署方案, \mathbf{X}_{SR} 代表源区域 R_{SR} 的实际部署结果。

定义5(电动车区域流量生成) 为方便起见,用 \mathbf{F}_{SR} 表示源区域 R_{SR} 的区域流量集合,用 $\hat{\mathbf{F}}_{TR}$ 表示目标区域 R_{TR} 需要生成流量的集合, $g(\cdot)$ 代表3.1.2节中所述的生成模型,则流量生成过程可表示为:

$$\hat{\mathbf{F}}_{TR} = g(\mathbf{X}_{SR}, \mathbf{F}_{SR}, D_{SR}, \mathbf{X}_{TR}, D_{TR}) \quad (2)$$

其中, D_{SR} 和 D_{TR} 分别代表了源区域和目标区域包含的环境信息和固有特征; \mathbf{X}_{SR} , \mathbf{F}_{SR} 和 D_{SR} 为模型训练时所需的数据, \mathbf{X}_{TR} 和 D_{TR} 为模型推理进行流量生成所需的数据。

定义6(换电站部署优化问题) 该问题旨在实现换电站与区域流量的高匹配,并扩大换电站网络的服务覆盖范围。换电站与区域流量的匹配度定义为 $\mathcal{R}_c(\mathbf{X}_{TR})$, 计算方式为:

$$\mathcal{R}_c(\mathbf{X}_{TR}) = \text{corr}(\text{Flow}_{TR}, \mathbf{X}_{TR}) \quad (3)$$

$\text{Flow}_{TR} = [\text{Flow}_1, \text{Flow}_2, \dots, \text{Flow}_m]$ 表示目标区域的流量值向量。其中,第 i 个区域的流量值 Flow_i 的计算方式为:

$$\text{Flow}_i = \sum_{t=1}^T \hat{f}_i^t * u_t \quad (4)$$

其中, u_t 为电动车区域流量在 t 时段的影响因子,可以通过用户的换电交易数据计算得到。具体而言,统计各时段的平均换电次数并归一化。 u_t 的值越接近1,代表该时段用户越可能进行换电,则该时段的区域流量影响越大。 $\text{corr}(\cdot)$ 为皮尔森指数计算函数,对换电站部署向量与目标区域流量向量进行计算后得到 $\mathcal{R}_c(\mathbf{X}_{TR})$ 。除此之外,换电站网络的服务覆盖范围 $\mathcal{R}_s(\mathbf{X}_{TR})$ 的计算方式为:如果区域 r_i 部署了换电站,则取 r_i 的中心点位置 c_i , 以 c_i 为圆心,设定服务半径 ρ 并构建圆形覆盖区域,处在该圆形区域内的范围即为换电站能服务的有效覆盖范围。对于所有部署了换电站的区域,计算换电站网络服务覆盖面积的并集并表示为 $\mathcal{R}_s(\mathbf{X}_{TR})$ 。为了消除不同量纲的影响,对 $\mathcal{R}_s(\mathbf{X}_{TR})$ 进行归一化处理。

因此,换电站部署优化问题定义为:

$$\max_{\mathbf{X}_{\text{TR}}} \mathcal{R}(\mathbf{X}_{\text{TR}}) = \alpha \cdot \mathcal{R}_c(\mathbf{X}_{\text{TR}}) + (1-\alpha) \cdot \mathcal{R}_s(\mathbf{X}_{\text{TR}}) \quad (5)$$

$$\text{s. t. } \sum_{j=1}^J e_j \leq B \quad (6)$$

$$\sum_{j=1}^J x_{ij} = \{0, \dots, C\}, i=1, \dots, I \quad (7)$$

其中, B 为总成本约束; C 为每个区域部署换电站数量的上限, 以避免不切实际的换电站数量分配。通过变量 α 来调节 $\mathcal{R}_c(\mathbf{X}_{\text{TR}})$ 和 $\mathcal{R}_s(\mathbf{X}_{\text{TR}})$ 的重要性程度。

该换电站部署优化问题能够被归约为经典的 NP-hard 最大覆盖问题^[34], 因此它可被证明为 NP-hard 问题。

证明: 考虑换电站部署优化问题中 $\alpha=0$ 的特例。将覆盖区域离散化成有限的网格点, 给定有限集合 $U = \{u_1, u_2, \dots, u_n\}$, 表示所有离散化网格点集合。给定 U 的子集的集合 $S = \{S_1, S_2, \dots, S_m\}$, 其中, S_j 表示换电站 w_j 对应的覆盖网络节点集合。约束 k 映射为换电站部署数量上限, 目标为选择覆盖最多网格点的 k 个换电站。因为最大覆盖问题是 NP-hard 的, 所以换电站部署优化问题也是 NP-hard 问题。证毕。

3.2.2 换电站部署优化问题求解

由于换电站部署优化问题是 NP-hard 问题, 因此不能在多项式时间内找到最优解。为了有效求解该问题, 本文采用了基于自适应遗传特性的换电站部署算法。算法包含 4 个部分: 种群初始化, 适应度评估, 自适应交叉、变异, 以及部署方案微调。

1) 种群初始化。给定 J 个待部署换电站和 M 个待部署区域。每一个可能的换电站部署方案用长度为 J 的列表或者染色体形式表示, 染色体的基因为区域编号 i , 代表第 j 个换电站被部署到了第 i 个区域, 在分配方案中表示为 $x_{ij} = 1$ 。染色体需要满足以下约束条件: (1) 长度必须等于预设的总站点数; (2) 所有站点的成本总和不能超过预算限制; (3) 每个区域最多只能部署 C 个站点; (4) 每个基因(区域)必须是待部署区域之一。种群初始化的目标是生成一组满足上述约束条件的随机个体。

2) 适应度评估。适应度值越高的染色体, 在种群进化中越容易被选择并保留。式(5)为适应度函数表达式。值得注意的是, 适应度函数的计算涉及到区域流量, 因此对区域流量进行预生成。此时, 流量先验网络所需的换电站区域特征(区域内的换电站数量、邻接区域内的换电站数量、邻近区域内的换电站数量)均计算自其他同类型企业的公开信息。此外, 通过精英保留的方式直接将当前种群中适应度最高的若干个体保留到新一代中。通过锦标赛选择法随机选择若干个体进行比赛, 并从中选择适应度最高的个体作为父代。

3) 自适应交叉、变异。遗传操作包括交叉操作和变异操作。交叉操作将两个父代个体的部分基因片段交换, 生成新的子代个体。变异操作是通过随机改变个体的某些基因, 即改变部署区域来引入新的遗传信息。交叉和变异后, 需要确保个体满足所有约束条件。为了收敛到更优的换电站部署方案, 同时避免陷入局部最优, 对交叉率 p_c 和变异率 p_m 进行自适应动态调整, 而不使用固定参数^[35]。

4) 部署方案微调。由表 1 可知, 区域流量与换电站部署之间存在显著的相关性。这种相关性并非单向的: 换电站的部署不仅受区域流量影响, 同时也会反过来影响流量分布。

因此, 流量先验网络所需的换电站区域特征应从部署方案中提取。然而, 如果对每一个部署方案都调用生成模型, 会造成大量的时间开销。为解决此问题, 对区域流量进行预生成并基于自适应遗传特性得到换电站部署初步方案, 然后利用部署方案微调^[5]的思想, 寻找换电站部署最终方案。具体而言, 对初步方案中部署了换电站的区域 i 添加随机扰动 δ_i , 且 $\delta_i \in \{-2, -1, 0, 1, 2\}$, 即改变区域 i 的换电站数量。该扰动随机传递给与区域 i 接壤或邻近的区域, 以确保换电站总部署数量不变。例如, 区域 a 接受了值为 1 的随机扰动, 则随机选择一个与区域 a 具有直接接壤或者邻近关系的区域 b , 区域 b 的换电站数量减少 1。此时, 如果新解满足式(6)和式(7), 则构造换电站区域特征, 调用生成模型。然后, 计算此时的 $\mathcal{R}(\mathbf{X}_{\text{TR}})$, 并更新部署方案结果。算法的具体细节如算法 1 所示。

算法 1 基于自适应遗传特性的换电站部署算法

输入: 待部署区域 R_{TR} , 换电站总数 J , 区域部署上限 C , 总成本约束 B , 最大迭代次数 MaxIter , $\text{MaxIter}'$, 精英保留数量 k , 竞标赛大小 T

输出: 最大化 $\mathcal{R}(\mathbf{X}_{\text{TR}})$ 的换电站部署方案

1. 区域流量预生成;
2. 初始化种群, 交叉率 p_c , 变异率 p_m ;
3. for $m = 1$ to MaxIter do
4. for all $q \in Q$ do
5. 根据式(5)计算适应度并更新最优解;
6. end for
7. 选择适应度最高的前 k 个精英个体;
8. 清空新种群 Q' 并加入精英个体;
9. while 新种群 Q' 未满足 do
10. 从 Q 中两轮随机选择 T 个个体, 适应度最高的为父代;
11. 计算自适应交叉率 p_c 和变异率 p_m ;
12. if $\text{random}(0, 1) < p_c$ then
13. 交叉操作;
14. end if
15. if $\text{random}(0, 1) < p_m$ then
16. 变异操作;
17. end if
18. if 新个体满足式(6)和式(7) then
19. 加入新种群 Q' ;
20. end if
21. end while
22. $Q \leftarrow Q'$;
23. end for
24. 输出适应度最高的个体并转换为换电站初步部署方案;
25. 构造区域特征, 调用生成模型, 重新计算初步方案的 $\mathcal{R}(\mathbf{X}_{\text{TR}})$;
26. for $m' = 1$ to $\text{MaxIter}'$ do
27. 对部署了换电站的区域添加随机扰动 δ ;
28. 扰动随机传递给一个接壤或邻近的区域;
29. if 新解满足式(6)和式(7) then
30. 构造区域特征, 调用生成模型, 计算并更新当前最优解;
31. end if
32. end for
33. 输出换电站最终部署方案;

4 实验评估

4.1 数据集与实验设置

本文使用四川省成都市一家换电企业提供的真实数据集进行实验评估。使用数据之前,需要先对缺失和异常的部分进行预处理及恢复工作。同时,根据 3.1.2 节中的方法为成都市构建换电知识图谱。实验中所需数据具体如下。1)区域:划分的待部署区域(测试区域)和已部署区域(训练区域)的地理位置如图 9 所示。其中,待部署区域数量为 151,已部署区域数量为 277。2)区域特征:流量先验网络所用的区域特征分为换电站特征和 POI 特征。其中,换电站特征进一步分为本区域内、邻接范围内、邻近范围内区域的换电站数量。POI 被分为 10 类,包括公司、教育、娱乐、餐饮、政府部门、住宅、酒店住宿、生活服务、医疗、购物。每个区域的 POI 特征为 30 维向量,包含本区域内、邻接范围内、邻近范围内 10 个类别 POI 的密度大小。3)区域流量:设时间间隔为 t 小时,一天被分为 T 个时间间隔。在本文实验中, t 设置为 1, T 设置为 24。

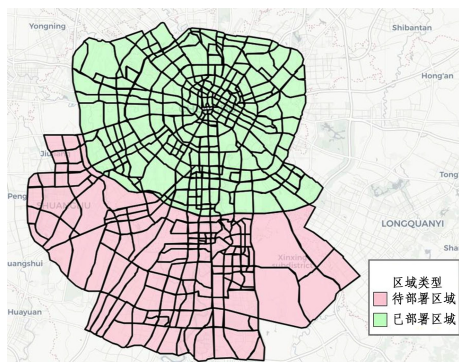


图 9 成都市待部署区域与已部署区域划分(电子版为彩图)

Fig. 9 Partitioning of candidate and existing deployment regions in Chengdu

智联电动车区域流量生成模型中,前向扩散通过 1000 步加噪成高斯噪声,逆向扩散通过 1000 步恢复数据。基于 PyTorch 框架实现生成模型,并在 NVIDIA RTX 4090 GPU 上进行训练和推理。基于自适应遗传特性的换电站部署算法中,精英保留数量为 6,锦标赛选择大小为 3。

4.2 智联电动车区域流量生成模型评估

4.2.1 对比方法

为了全面对比生成模型的性能,采用以下 4 种模型进行对比。

1)DDPM^[29]:生成模型,采用 U-Net 作为去噪网络,基于扩散过程逐步向数据添加噪声,然后通过逆过程去噪生成新数据。

2)GAN^[36]:生成模型,由生成器和判别器两个网络组成。生成器生成伪造数据,判别器区分真伪,二者通过对抗训练实现数据生成。

3)RNN^[37]:预测模型,具有循环结构的神经网络,能够利用序列数据的上下文信息。

4)LSTM^[38]:预测模型,通过引入记忆单元和门控机制,捕捉序列数据中的长程依赖关系。其中,预测模型无法在无

历史数据的情况下预测流量。因此,本文实验采用了 7 天的历史数据作为输入。

4.2.2 性能评估指标

本文在智联电动车区域流量生成模型实验评估中采用 4 种性能评估指标。

- 1)MAE:预测值与真实值之间误差的绝对值平均。
- 2)RMSE:均方误差的平方根。
- 3)SMAPE:对称的平均百分比误差。
- 4)MMD:度量两个分布之间的差异。

4.2.3 实验结果

智联电动车区域流量生成模型与对比模型在 4 个指标上的对比结果如表 2 所列。

表 2 与基线的性能比较

Table 2 Performance comparison with baselines

模型	指标			
	MAE	RMSE	SMAPE	MMD
DDPM	6.30	14.35	1.77	2.87
GAN	6.28	14.35	1.91	3.66
LSTM	4.90	11.56	1.05	3.01
RNN	5.33	12.22	1.13	4.90
本文模型	4.73	11.38	1.02	2.05

本文采用的智联电动车生成模型在所有指标上都优于对比模型,相较于 DDPM,GAN,LSTM,RNN 在 MAE 上分别提升 24.9%,24.7%,3.5%,11.3%,在 RMSE 上分别提升 20.7%,20.7%,1.6%,6.9%,在 SMAPE 上分别提升 42.4%,46.6%,2.9%,9.7%,在 MMD 上分别提升 28.6%,44.0%,31.9%,58.2%。值得注意的是,为了让预测模型 LSTM 和 RNN 能输出智联电动车区域流量,在模型中输入了 7 天的历史数据(在实际场景中并没有历史数据),但本文生成模型在所有指标上仍优于这两个预测模型,证明了本文生成模型的有效性和可用性。

4.3 基于自适应遗传特性的换电站部署算法评估

4.3.1 实验对比方法

为了评估自适应遗传算法 AGA(Adaptive Genetic Algorithm)的性能,本文采用 3 种对比方法。

1)遗传算法 GA(Genetic Algorithm):与自适应遗传算法相比,不根据个体的适应度动态调整交叉率和变异率。

2)Charger-based Greedy(CG) Algorithm^[20]:每次选择边际效益最大的区域部署换电站。


3)模拟退火 SA(Simulated Annealing):通过模拟物理退火过程,动态调整搜索策略。

4.3.2 性能评估指标




本文在基于自适应遗传特性的换电站部署算法实验评估中比较总收益值 $\mathcal{R}(\mathbf{X}_{TR})$, $\mathcal{R}_c(\mathbf{X}_{TR})$ 和 $\mathcal{R}_s(\mathbf{X}_{TR})$ 加权后的值。

4.3.3 实验结果

1)参数 α 对效益的影响。图 10 展示了不同 α 值下的总效益值 $\mathcal{R}(\mathbf{X}_{TR})$ 的变化情况。 α 的选取值在 $[0.35, 0.65]$,以避免过分偏向任一目标,确保模型取得合理平衡。在 α 取值为 0.35~0.5 时, $\mathcal{R}(\mathbf{X}_{TR})$ 逐渐减小。当 α 在 0.5~0.65 时, $\mathcal{R}(\mathbf{X}_{TR})$ 逐渐增大,并在 0.65 时取得最大值。在本文实验中, α 被最终设置为 0.65。

图 10 不同 α 值下的 $R(X_{TR})$ Fig. 10 $R(X_{TR})$ for varying α

2) 换电站部署数量对效益的影响。在换电站数量由 30 逐步增加至 70 的过程中, 探究换电站部署数量对效益的影响。图 11 展示了在不同换电站数量(30, 40, 50, 60, 70)下, 4 种算法对总效益值 $R(X_{TR})$ 的影响。本文算法在各个换电站数量设置下均取得了最好的性能表现。图 12 和图 13 展示了换电站数量对 $R_c(X_{TR})$ 加权值和 $R_s(X_{TR})$ 加权值的影响。

图 11 不同换电站数量下的 $R(X_{TR})$ Fig. 11 $R(X_{TR})$ for varying numbers of BSSs图 12 不同换电站数量下的 $R_c(X_{TR})$ Fig. 12 $R_c(X_{TR})$ for varying numbers of BSSs图 13 不同换电站数量下的 $R_s(X_{TR})$ Fig. 13 $R_s(X_{TR})$ for varying numbers of BSSs

对于前者, 本文算法在不同换电站数量下的效益都与对比算法相当或优于对比算法。同时, 本文提出的换电站部署优化问题是一个组合优化问题, 在平衡参数 α 的影响下, 本文算法可以寻找到组合优化结果更好的方案。总的来说, 由于本文的换电站部署问题含有部署成本上限, 采用每次选

择边际效益最大区域的策略虽在前期能够取得较好的效果, 但容易导致后续部署选择空间受限, 影响整体方案的最优性。同时, 另外两种启发类算法在搜索过程中容易陷入局部最优解, 导致最终解的质量不高, 其中 SA 算法的稳定性更差。

5 总结与展望

5.1 工作总结

为突破跨区域场景下进行换电站部署决策时的循环困境, 本文提出基于智联电动车流量生成的换电站部署算法, 使换电站数量与区域流量之间的匹配度、换电站网络服务覆盖范围达到最佳的平衡。实验结果表明, 所提方法在智联电动车区域流量生成模块和基于自适应遗传特性的换电站部署优化问题求解模块的评估结果都优于对比算法。

5.2 研究展望

在后续的研究进程中, 仍需针对本研究的缺点与不足之处加以完善, 主要包括以下两个方面。

1) 本文的部署优化模型中, 仅考虑了生成智联电动车区域流量, 并没有考虑到生成区域换电需求。在换电场景中, 用户的换电需求分布对换电站的选址也具有重要意义。因此, 如何划分智联电动车换电需求^[39-40]并分析数据特征, 设计生成模型以实现区域换电需求生成, 是下一步的研究工作。

2) 换电站部署扩张有同城市跨区域扩张、跨城市扩张等方案。本文考虑的是在某城市部分区域已经部署了换电站后需要向剩下的区域扩张规模的情况, 对于跨城市扩张并未展开讨论。未来将考虑利用某几个城市的部署方案为新城市提供部署方案指导^[41-42]。例如, 可设计跨城市表征学习框架, 基于源城市的交通数据和换电站布局, 学习可迁移的换电站表征向量, 并结合目标城市的知识图谱实现初始流量分布估计, 从而辅助目标城市的部署策略设计。

参考文献

- [1] As social ownership reaches 350 million units, three ministries will jointly release a list of compliant e-scooter enterprises. [EB/OL]. (2024-05-08) [2024-10-09]. <https://baijiahao.baidu.com/s?id=1798469716536620755&wfr=spider&for=pc>.
- [2] How much do you know about the fire safety risks of e-scooters? [EB/OL]. (2024-12-20) [2024-10-20]. <https://baijiahao.baidu.com/s?id=1815601399691677843&wfr=spider&for=pc>.
- [3] ZHOU E, LI Z, LIU D, et al. Balancing Electric Scooter Battery Swapping Network by Spatio-Temporal Recommendation [J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(12): 21315-21326.
- [4] Gogoro Network upgrades battery swapping ecosystem, targeting 94% coverage across Taiwan by 2024. [EB/OL]. (2023-10-04) [2025-03-10]. <https://baijiahao.baidu.com/s?id=1778807649215044254&wfr=spider&for=pc>.
- [5] WANG Y, ZHAO D, REN Y, et al. SPAP: Simultaneous demand prediction and planning for electric vehicle chargers in a new city

- [J]. *ACM Transactions on Knowledge Discovery from Data*, 2023,17(4):1-25.
- [6] HO J,SALIMANS T,GRITSENKO A,et al. Video diffusion models [J]. *Advances in Neural Information Processing Systems*,2022,35:8633-8646.
- [7] BATZOLIS G,STANCZUK J,SCHÖNLIEB C B, et al. Conditional image generation with score-based diffusion models [J]. arXiv:2111.13606,2021.
- [8] LI X,THICKSTUN J,GULRAJANI I,et al. Diffusion-lm improves controllable text generation [C] // *Proceedings of the 36th International Conference on Neural Information Processing System*. 2022:4328-4343.
- [9] AUSTIN J,JOHNSON D D, HO J, et al. Structured denoising diffusion models in discrete state-spaces [C] // *Proceedings of the 35th International Conference on Neural Information Processing Systems*. 2021:17981-17993.
- [10] TASHIRO Y,SONG J,SONG Y,et al. Csd: Conditional score-based diffusion models for probabilistic time series imputation [C] // *NeurIPS 2021*. 2021:24804-24816.
- [11] YAN T,ZHANG H,ZHOU T,et al. Scoregrad: Multivariate probabilistic time series forecasting with continuous energy-based generative models [J]. arXiv:2106.10121,2021.
- [12] CHEN N,ZHANG Y,ZEN H,et al. Wavegrad: Estimating gradients for waveform generation [J]. arXiv:2009.00713,2020.
- [13] POPOV V,VOVK I,GOGORYAN V,et al. Grad-tts: A diffusion probabilistic model for text-to-speech [C] // *Proceedings of International Conference on Machine Learning*. PMLR, 2021: 8599-8608.
- [14] HUANG H,SUN L,DU B, et al. Graphdp: Generative diffusion processes for permutation invariant graph generation [C] // *Proceedings of 2022 IEEE International Conference on Data Mining(ICDM)*. IEEE,2022:201-210.
- [15] NIU C,SONG Y,SONG J,et al. Permutation invariant graph generation via score-based generative modeling [C] // *Proceedings of International Conference on Artificial Intelligence and Statistics*. PMLR,2020:4474-4484.
- [16] The battery swapping industry for e-scooters is poised for more intelligent and refined development [EB/OL]. (2023-06-20) [2024-11-21]. <https://baijiahao.baidu.com/s?id=1769188866287918201&wfr=spider&for=pc>.
- [17] LI K,ZHANG Y,DU C,et al. Dynamic Programming-Based Optimal Charging Scheduling for Electric Vehicles [C] // *Proceedings of 2022 IEEE 7th International Conference on Intelligent Transportation Engineering(ICITE)*. IEEE,2022:545-550.
- [18] XIONG Y,GAN J,AN B, et al. Optimal electric vehicle fast charging station placement based on game theoretical framework [J]. *IEEE Transactions on Intelligent Transportation Systems*,2017,19(8):2493-2504.
- [19] LI Y,LUO J,CHOW C Y,et al. Growing the charging station network for electric vehicles with trajectory data analytics [C] // *Proceedings of 2015 IEEE 31st International Conference on Data Engineering*. IEEE,2015:1376-1387.
- [20] DU B,TONG Y,ZHOU Z,et al. Demand-aware charger planning for electric vehicle sharing [C] // *Proceedings of Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. 2018:1330-1338.
- [21] VON WAHL L,TEMPELMEIER N,SAO A, et al. Reinforcement learning-based placement of charging stations in urban road networks [C] // *Proceedings of Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. 2022:3992-4000.
- [22] BAE S,JANG I,GROS S,et al. A game approach for charging station placement based on user preferences and crowdedness [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2020,23(4):3654-3669.
- [23] WANG L,GENG X,MA X,et al. Cross-city transfer learning for deep spatio-temporal prediction [J]. arXiv:1802.00386, 2018.
- [24] ZHANG S,LI T,HUI S,et al. Deep transfer learning for city-scale cellular traffic generation through urban knowledge graph [C] // *Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. 2023:4842-4851.
- [25] RONG C,DING J,LIU Z, et al. Complexity-aware large scale origin-destination network generation via diffusion model [J]. arXiv:2306.04873,2023.
- [26] LI J,XIAO Y,WU J, et al. Attentive dual-head spatial-temporal generative adversarial networks for crowd flow generation [C] // *Proceedings of 2022 IEEE 33rd Annual International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC)*. IEEE,2022:800-806.
- [27] Who are the main users of battery swapping services for e-scooters? What market needs do they address? [EB/OL]. (2024-01-05) [2024-11-21]. <https://baijiahao.baidu.com/s?id=1787232553503955719&wfr=spider&for=pc>.
- [28] ZHOU Z,DING J,LIU Y, et al. Towards generative modeling of urban flow through knowledge-enhanced denoising diffusion [C] // *Proceedings of the 31st ACM International Conference on Advances in Geographic Information Systems*. 2023:1-12.
- [29] HO J,JAIN A,ABBEEL P. Denoising diffusion probabilistic models [J]. arXiv.2006.11239,2020.
- [30] HAN X,ZHENG H,ZHOU M. Card: Classification and regression diffusion models [J]. arXiv:2206.07275,2022.
- [31] LIU Y,DING J,FU Y, et al. Urbankg: An urban knowledge graph system [J]. *ACM Transactions on Intelligent Systems and Technology*,2023,14(4):1-25.
- [32] BALAŽEVIĆ I,ALLEN C,HOSPEDALES T M. Tucker: Tensor factorization for knowledge graph completion [J]. arXiv:1901.09590,2019.
- [33] KONG Z,PING W,HUANG J, et al. Diffwave: A versatile diffusion model for audio synthesis [J]. arXiv:2009.09761,2020.
- [34] HOCHBA D S. Approximation algorithms for NP-hard problems [J]. *ACM Sigact News*,1997,28(2):40-52.
- [35] SRINIVAS M,PATNAIK L M. Adaptive probabilities of crossover and mutation in genetic algorithms [J]. *IEEE Transactions*

on Systems, Man, and Cybernetics, 2002, 24(4):656-667.

- [36] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks [J]. Communications of the ACM, 2020, 63(11):139-144.
- [37] ELMAN J L. Finding structure in time [J]. Cognitive Science, 1990, 14(2):179-211.
- [38] HOCHREITER S, SCHMIDHUBER J. Long Short-term Memory [J]. Neural Computation, 1997, 9(8):1735-1780.
- [39] ZHAO L, SHEN S, ZHAO Z. Planning decentralized battery-swapping recharging facilities for e-bike sharing systems [J]. Sustainable Cities and Society, 2024, 101:105118.
- [40] KOOLMAN G, STECCA M, BAUER P. Optimal battery energy storage system sizing for demand charge management in ev fast charging stations [C] // Proceedings of 2021 IEEE Transportation Electrification Conference & Expo (ITEC). IEEE, 2021: 588-594.
- [41] LIU Z, ZHENG G, YU Y. Cross-city few-shot traffic forecasting via traffic pattern bank [C] // Proceedings of the 32nd ACM International Conference on Information and Knowledge Manage-

ment, 2023:1451-1460.

- [42] MO J, GONG Z. Cross-city multi-granular adaptive transfer learning for traffic flow prediction [J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 35(11):11246-11258.



CHEN Jiayi, born in 2000, postgraduate. Her main research interests include urban computing and edge computing.



ZHAO Tao, born in 1983, professor, master's supervisor. His main research interests include IoT networks and broadband intelligent communications.

(责任编辑:何杨)