

融合多源城市环境信息的知识图谱驱动轨迹生成模型

李 康¹, 于 娟^{1*}, 韩建民¹, 邱 晟¹, 杨 琼²

(1. 浙江师范大学计算机与科学技术学院, 浙江金华 321004; 2. 浙江工业职业技术学院信息与设计学院, 浙江绍兴 312099)

摘要: 在城市环境下, 人、车等对象的移动轨迹数据蕴含着丰富的居民活动信息, 对城市规划、交通管控和流行病传播分析等具有重要价值. 然而, 隐私保护和商业机密等因素极大地限制了轨迹数据的共享和使用. 生成能够保留真实轨迹特征的合成轨迹, 以代替真实轨迹发布应用, 已成为突破此限制的一种优选方案. 近期, 基于深度学习技术的轨迹生成研究颇受学术和工业界的关注, 基于生成对抗网络(Generative Adversarial Networks, GAN)、扩散模型等的轨迹模型相继提出. 但现有轨迹生成模型存在两大局限: 其一, 未能有效捕获人类移动轨迹中的全局空间依赖关系; 其二, 未能有效建模城市环境对轨迹生成的影响, 导致生成的轨迹与真实场景存在偏差. 为此, 本文提出融合多源城市环境信息的知识图谱驱动轨迹生成模型(urban Trajectory Generation via Knowledge Graph-enhanced multi-source context fusion, KG-TrajGen). 首先, 该模型整合路网拓扑数据、兴趣点(Point Of Interest, POI)、功能区域划分情况等关键的多源城市环境数据, 分别构建基础的道路知识图谱(Road Knowledge Graph, RKG)和环境语义增强型道路知识图谱(Environment-semantics-enhanced Road Knowledge Graph, E-RKG), 并采用关系图卷积网络(Relational Graph Convolutional Network, R-GCN), 从RKG中学习路段基础嵌入, 以同时捕捉道路间的局部和全局空间依赖关系, 采用结构感知的知识图谱嵌入方法, 从E-RKG中学习城市环境知识, 赋予模型环境感知能力, 以进一步丰富路段嵌入特征. 其次, 采用Transformer解码器模型, 从历史轨迹数据中学习城市中的人类活动模式特征, 获取到历史轨迹数据增强的路段嵌入特征. 最后, 通过有效融合知识图谱增强的路段嵌入和历史轨迹数据增强的路段嵌入特征, 以自回归方式实现环境感知的细粒度轨迹生成. 在两个开源的真实轨迹数据集上的实验表明: KG-TrajGen在统计特征误差、频繁模式特征误差和轨迹误差方面的指标显著优于基线方法, 且生成的轨迹能够在交通流量预测这一下游轨迹分析任务上也优于基线方法, 充分验证了KG-TrajGen模型的有效性. KG-TrajGen模型的代码可在<https://github.com/trajgen/KG-TrajGen>获得.

关键词: 知识图谱; 路网; 轨迹生成; 隐私保护; 城市环境; Transformer

基金项目: 教育部人文社会科学研究项目(No.22YJCZH215); 浙江省高校重大人文社科攻关计划项目(No.2023QN150); 国家自然科学基金(No.61702148, No.61672648)

中图分类号: TP309.2

文献标识码: A

文章编号: 0372-2112(2025)10-3551-15

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20250307

Urban Trajectory Generation via Knowledge Graph-Enhanced Multi-Source Context Fusion

LI Kang¹, YU Juan^{1*}, HAN Jian-min¹, QIU Sheng¹, YANG Qiong²

(1. School of Computer Science and Technology, Zhejiang Normal University, Jinhua, Zhejiang 321004, China;

2. School of Information and Design, Zhejiang Industry Polytechnic College, Shaoxing, Zhejiang 312099, China)

Abstract: Mobility trajectory data of individuals, vehicles, and other objects in urban environments contains rich information about residents' activities, which is highly valuable for urban planning, traffic management, and epidemic spread analysis. However, privacy protection and commercial confidentiality significantly restrict the sharing and utilization of trajectory data. Generating synthetic trajectories that preserve the characteristics of real trajectories to replace real ones for release and application has become a preferred solution to overcome these limitations. Recently, deep learning-based trajectory generation research has attracted considerable attention from both academia and industry, with various trajectory

models based on generative adversarial networks, diffusion models, and others being successively proposed. Nevertheless, existing trajectory generation models suffer from two major limitations: first, they fail to effectively capture global spatial dependencies in human mobility patterns; second, they inadequately model the influence of urban environments on trajectory generation, leading to deviations between generated trajectories and real-world scenarios. To address this, this paper proposes a knowledge graph-driven trajectory generation model integrating multi-source urban environmental information, named urban trajectory generation via knowledge graph-enhanced multi-source context fusion (KG-TrajGen). The model integrates key multi-source urban environmental data, including road network topology, points of interest (POI), and functional zone classifications, to construct a foundational road knowledge graph (RKG) and an environment-semantics-enhanced road knowledge graph (E-RKG). A relational graph convolutional network is employed to learn basic road segment embeddings from the RKG, simultaneously capturing both local and global spatial dependencies among roads. Additionally, a structure-aware knowledge graph embedding method is used to extract urban environmental knowledge from the E-RKG, endowing the model with environmental awareness and enriching the road segment embedding features. Subsequently, a Transformer decoder model learns human activity pattern features from historical trajectory data to obtain trajectory history-enhanced road segment embeddings. Finally, by effectively fusing the knowledge graph-enhanced and historical trajectory-enhanced road segment embeddings, the model generates environment-aware, fine-grained trajectories in an autoregressive manner. Experiments on two open source real world trajectory datasets demonstrate that KG-TrajGen significantly outperforms baseline methods in terms of statistical feature error, frequent pattern feature error, and trajectory error metrics. Moreover, the generated trajectories perform better than those from baseline methods in downstream trajectory analysis tasks such as traffic flow prediction, fully validating the effectiveness of the KG-TrajGen model. The code for KG-TrajGen is available at <https://github.com/trajgen/KG-TrajGen>.

Key words: knowledge graph; road network; trajectory generation; privacy protection; urban environment; Transformer

Foundation Item(s): Humanities and Social Sciences Project of the Ministry of Education of China (No.22YJCZH215); Major Humanities and Social Sciences Research Projects in Zhejiang Higher Education Institutions (No.2023QN150); National Natural Science Foundation of China (No.61702148, No.61672648)

1 引言

高质量时空轨迹数据作为城市计算与移动感知研究的核心支撑,在许多时空数据挖掘应用中起着至关重要的作用,包括城市规划、交通管控和流行病传播分析^[1,2]。然而,在实际场景中获取高质量轨迹数据面临诸多障碍,例如,高昂数据收集成本,隐私保护问题、商业限制等^[3-5],进而阻碍大多数数据驱动研究。在此背景下,采用先进人工智能方法生成能够反映人类真实移动规律,以及统计特征的高质量合成轨迹,成为一种可行方法^[2],能够在保证数据效用的同时解决上述问题。因此,如何生成高质量的合成轨迹成为当前时空数据挖掘领域一个热门的研究方向。

有关移动轨迹生成的研究已持续近十年。早期,研究者们主要采用统计模型建模人类移动行为,例如,重力模型及其扩展模型等^[6,7]。然而,这些统计模型方法往往采用较强假设以简化问题,难以捕捉复杂的人类移动规律。例如,时间地理建模框架(TimeGeo modeling framework, TimeGeo)模型^[7]假设人们工作的时间和地点固定。近期,随着深度生成技术的兴起,相关技术开始不断地用于轨迹生成任务。例如,生成对抗网络(Generative Adversarial Networks, GAN)、变分自编码器(Variational AutoEncoder, VAE)、扩散模型等,并取得了

突破性进展。然而,现有基于深度学习的方法大都将全球定位系统(Global Position System, GPS)轨迹粗化为网格序列或图像,例如,移动模拟(Mobility Simulation, MoveSim)^[2]、轨迹生成(Trajectory Generation, TrajGen)^[8]、两阶段生成对抗网络(Two-Stage GAN, TSG)^[9]等,这种方式虽有利于捕捉整体模式,但会忽略轨迹的细节,难以满足细粒度移动轨迹的生成要求。相比之下,将GPS轨迹转化为路段轨迹再生成,可保留更多细节和语义信息,如路网的实际连接关系等。最近,基于路段轨迹的生成模型研究逐渐占据主导,典型模型包括:知识增强时空(Knowledge-enhanced SpatioTemporal, Know-ST)^[10]、时空门控注意力(SpatioTEmporal Gated Attention, STEGA)^[11]、两阶段轨迹生成(Two-Stage Trajectory Generation, TS-TrajGen)^[1]。尽管路段轨迹生成模型已取得一定进展,但它们仍存在以下两个局限:

(1)未能有效捕获人类移动轨迹中的全局空间依赖关系。从北京出租车轨迹数据集中选择三条道路统计其访问频率。统计结果如图1(a)所示,其中道路一和道路二相邻,道路二和道路三距离较远但周围兴趣点(Point Of Interest, POI)分布相似。由图1(a)可知,道路一和道路二因相邻而展现出相似移动模式,体现了局部空间关联;而道路二和道路三虽相距较远,但因周边POI分布相似,也呈现出相似的移动模式,揭示了全局

空间关联. 这表明人类移动轨迹不仅存在局部空间关联, 还存在全局空间关联, 且后者与道路周围 POI 分布密切相关. 然而, 现有路段轨迹生成模型^[1, 10, 11]仅通过道路邻接关系建模局部空间关联, 忽略了全局空间依赖关系的捕获.

(2) 未能有效建模城市环境对轨迹生成的影响. 从北京轨迹数据集中选择不同类型城市功能区的两条道路, 统计其访问频率. 统计结果如图 1(b) 和图 1(c) 所示, 不同类型城市功能区的活动模式呈现显著差异, 工业区的道路在工作日早晚高峰表现出明显通勤特征,

周末流量则显著下降; 自然风景区的道路则因游客访问集中于午间时段而呈现单峰分布. 由于轨迹生成本质上是模拟人类活动行为, 因此将城市环境因素纳入模型有助于更准确地捕捉人类移动规律, 生成更真实的轨迹. 此外, 虽已有轨迹生成模型^[10]尝试使用知识图谱整合环境语义信息, 但忽略了几何结构建模的重要性^[12], 即区域层次结构建模(如 POI→功能区→行政区)和环形结构建模(如行政区 A、B 和 C 两两相邻)的重要性, 导致构建的知识图谱难以充分表示复杂的城市环境.




图 1 道路访问频率统计信息

为克服现有模型的上述局限, 本文结合知识图谱, 提出一个融合多源城市环境信息的知识图谱驱动轨迹生成模型(urban Trajectory Generation via Knowledge Graph-enhanced multi-source context fusion, KG-TrajGen). 首先, 本文构建基础的道路知识图谱(Road Knowledge Graph, RKG), 用于捕捉道路间的局部和全局空间依赖, 并在此基础上引入 POI、功能区、行政区等关键城市要素, 构建几何结构鲜明的环境语义增强型道路知识图谱(Environment-semantics-enhanced Road Knowledge Graph, E-RKG), 以更全面地表征城市环境特性. 具体地, 在 KG-TrajGen 模型的时空嵌入模块中引入关系图卷积网络(Relational Graph Convolutional Network, R-GCN), 从 RKG 中学习信息丰富的路段(即道路)编码, 即增强的空间特征, 作为 Transformer 解码器的输入. 接着, 结合 Transformer 解码器与结构感知的知识图谱嵌入(Geometry Interaction knowledge graph Embeddings, GIE)方法^[13], 从轨迹与 E-RKG 中学习富含环境上下文信息的轨迹嵌入向量, 即知识图谱增强的轨迹嵌入. 其中, Transformer 解码器负责提取基础轨迹嵌入, GIE 负责从 E-RKG 中提取环境知识嵌入, 并采用多层感知器(MultiLayer Perceptron, MLP)融合两者, 得到知识图谱增强的轨迹嵌入, 用于后续预测任务. 由此, 增强了轨迹生成模型捕获复杂空间依赖关系和城市环境影响的能力. 本文主要贡献如下:

(1) 为了利用多源城市环境信息, 将城市中的关键要素和复杂关系分别识别为实体和关系, 构建 RKG 和

E-RKG. 其中, RKG 用于捕捉道路间局部与全局空间依赖, E-RKG 则负责建模道路与周围复杂城市环境的交互关系.

(2) 提出了一种 KG-TrajGen, 通过融合环境信息以生成更加真实的轨迹. 该模型有效结合生成式 Transformer 与结构感知知识图谱嵌入方法 GIE, 能够从轨迹与 E-RKG 中学到富含环境上下文的轨迹嵌入向量, 有效支撑后续的预测任务.

(3) 在两个真实轨迹数据集上的实验表明: KG-TrajGen 在定量与可视化分析中均展现出显著优势, 验证了模型的有效性.

2 相关工作

2.1 城市知识图谱

现有基于机器学习的方法^[14]仅考虑特定背景下的轨迹表示, 并未充分利用广泛的的城市知识. 知识图谱已被证明是组织复杂关系和表示多源知识的强大工具^[15], 因此一些后续研究^[16]尝试使用知识图谱来表示城市知识, 用于轨迹分析任务, 然而这些方法仅考虑 POI 信息, 忽略了路网结构及城市功能分布等因素. 最近的研究^[10]虽然致力于构建更全面的知识图谱, 但忽略了几何结构(如层次结构与环形结构)建模对城市知识表示的重要性, 研究表明^[12]: 获取这种结构语义知识对各种下游任务有益. 因此, 本文旨在构建能够建模层次结构与环形结构特征的知识图谱, 以有效捕捉道路周围的城市环境信息. 同时, 为使实体嵌入更适合轨迹

生成任务,本文使用R-GCN学习动态实体嵌入,进而增强模型捕捉复杂城市动态的能力.

2.2 移动轨迹生成

轨迹生成方法旨在生成能够准确反映人类移动行为模式的轨迹,现有方法可分为两类:基于模型的方法和基于深度学习的方法.基于模型的方法^[6,7]依赖于特定的强假设来对人类移动行为建模,然而,由于人类移动行为的复杂性,有限的物理参数难以完全捕捉其规律.基于深度学习的方法则利用深度学习技术来捕捉人类移动行为规律,如GAN和VAE.这类模型大多将GPS轨迹映射到空间网格^[2],导致只能捕捉粗粒度行为模式,丢失细粒度行为模式.还有一些工作则是将轨迹转为图像^[8,9],利用图像生成模型来捕捉轨迹空间特征,但轨迹与图像的转换会带来额外的计算负担,且会引入转换误差.近来,扩散模型^[17]也开始应用于轨迹生成,尽管此类模型能够保留细粒度轨迹信息,但缺乏可控性.此外,受生成式预训练变换器(Generative Pre-trained Transformer, GPT)启发,Transformer解码器也被用于轨迹表示和预测^[11].尽管上述方法已取得较好的进展,但它们仍普遍忽略了城市环境对轨迹生成的影响,且未考虑道路间的全局空间依赖关系.

3 基本概念

定义 1 路网.城市道路网络可形式化描述为有向图 $G=(V,E,A)$,其中 $V=\{v_1,v_2,\dots,v_N\}$ 为节点集, $N=|V|$ 为节点个数,每个节点 v_i 表示路网中的路段 r_i . E 表示相邻路段之间的交叉点(边)集. $A \in \mathbb{R}^{N \times N}$ 为二元邻接矩

阵,当路段 r_i 与路段 r_j 直接连接时 $A_{i,j}=1$,否则 $A_{i,j}=0$.

定义 2 路段轨迹.路段轨迹由一系列连续路段组成,表示为 $x=[p_1,p_2,\dots,p_n]$,其中 $p_i=(r_i,t_i)$, r_i 表示路网 G 中的路段, t_i 表示 p_i 对应的时间戳.

定义 3 城市知识图谱.城市知识图谱定义为多关系图 $G=(\mathcal{E},\mathcal{R},\mathcal{F})$,其中 \mathcal{E} 、 \mathcal{R} 和 \mathcal{F} 分别表示城市实体集、关系集和事实集,其中事实集定义为 $\mathcal{F}=\{(h,r,t)|h,t \in \mathcal{E},r \in \mathcal{R}\}$.每个三元组 $(h,r,t) \in \mathcal{F}$ 表示头实体 h 通过关系 r 与尾实体 t 相关联.

定义 4 问题定义.给定真实的路段轨迹数据集 $T=\{x_1,x_2,\dots,x_m\}$,轨迹生成的目标是模拟人类移动行为,生成能保留真实轨迹数据集时空特征的合成路段轨迹集合 $\hat{T}=\{\hat{x}_1,\hat{x}_2,\dots,\hat{x}_m\}$.

4 方法

KG-TrajGen 模型以路段轨迹、RKG、E-RKG 和路段特征为输入来生成轨迹,其结构如图 2 所示,主要包含 5 个模块:(1)时空嵌入模块,采用 R-GCN 从 RKG 中学习全面的路段表示,并结合傅里叶变换编码时间戳,以捕捉轨迹中的复杂时空特征;(2)轨迹嵌入模块,采用因果注意力机制对轨迹移动状态建模,以递归的方式学习整个轨迹序列的表示向量;(3)环境知识嵌入模块,利用结构感知 GIE 从 E-RKG 中学习环境知识嵌入;(4)特征融合模块,采用 MLP 融合轨迹嵌入与环境知识嵌入,生成环境感知的轨迹嵌入;(5)预测模块,采用两个线性层以环境感知的轨迹嵌入为输入预测下一个路段和行驶时间,自回归地生成轨迹.其中,前 4 个模块主要负责学习知识图谱增强的轨迹嵌入.

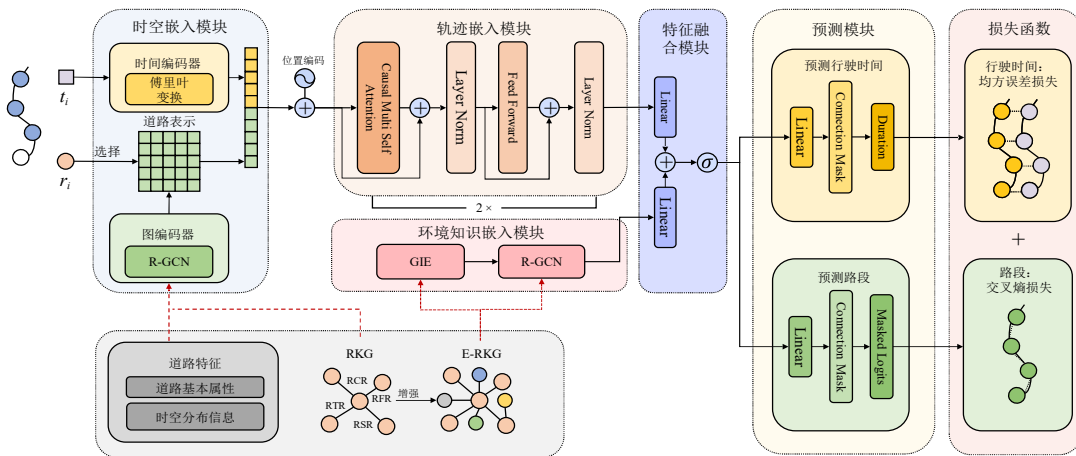


图 2 KG-TrajGen 模型框架图

4.1 知识图谱构建

模型需要构建 RKG 和 E-RKG 作为输入. 其中, RKG 的实体仅包含路段, 旨在捕捉路段间的局部和全局空间依赖关系, 强调路网本身的拓扑结构和语义联系. 相比之下, E-RKG 则建模了更丰富的城市实体类型, 除路段外, 还包含 POI、功能区等多种类型, 通过引入这些多样化的城市环境信息, E-RKG 能够提供更全面的城市环境理解. 但 E-RKG 不能替代 RKG, 因为仅用 E-RKG 的模型会过度依赖城市环境信息, 而忽略道路网络本身的拓扑结构和语义关系.

4.1.1 RKG 的构建

构建的 RKG 共归纳了 4 种关系: 路段的物理拓扑连接关系、基于历史轨迹的路段迁移关系、空间布局相似性以及时间模式相似性的关系. 前两种关系侧重于直连路段间的联系, 即局部空间依赖关系; 而后两种关系则是为了捕捉地理位置相隔较远的路段间的隐含联系. 下文将详细介绍这 4 种关系:

(1) 路段的物理拓扑连接关系. 此关系利用路网拓扑结构表示路段的物理连接, 即表示为定义 1 中的路网邻接矩阵 A .

(2) 基于历史轨迹的路段迁移关系. 由于路段的物理连接关系仅反映道路的直接连通性, 不能反映轨迹中的出行模式. 为弥补这一不足, 本文构建基于历史轨迹的路段迁移关系以更好地建模轨迹中的行为特征和偏好, 通过从真实轨迹数据集 T 中统计路段间的迁移频率, 构建历史迁移矩阵, 其中的元素 a_{ij} 表示统计得到的路段 r_i 和 r_j 的迁移频率:

$$a_{ij} = \sum_{(r_i, r_j) \in T} f(r_i, r_j) \quad (1)$$

其中, $j = i + 1$; (r_i, r_j) 表示轨迹数据集 T 中某条轨迹的一对连续路段, r_i 和 r_j 之间若存在迁移关系, 则被记录为 $f(r_i, r_j) = 1$.

(3) 基于空间布局相似性的关系. 刻画路段间的全局依赖关系. 在城市中, POI 分布是反映城市区域功能的重要指标, 对于地理距离相距较远的两个路段, 若它们的 POI 分布相似, 则可表明它们的功能相似, 即它们间存在隐含联系. 为量化这种相似性, 首先统计每个路段的 POI 分布矩阵 $P \in \mathbb{R}^{N \times N^p}$, 其中 N 表示路段数量, N^p 为 POI 类别数. 然后利用 POI 分布的余弦相似度度量路段间的空间布局相似性, 例如, 路段 r_i 和 r_j 间的 POI 分布余弦相似度 b_{ij} 可计算为

$$b_{ij} = \cos(\mathbf{v}_i^{\text{POI}}, \mathbf{v}_j^{\text{POI}}) \quad (2)$$

其中, $\mathbf{v}_i^{\text{POI}}$ 表示路段 r_i 的 POI 分布向量.

(4) 基于时间模式相似性的关系. 从时间维度刻画

路段间的全局依赖关系, 补充了仅考虑空间特征时可能忽略的信息. 两条地理位置相距甚远的路段, 若它们一周的移动模式在时间上表现出相似性, 则它们也存在隐含联系. 首先从真实轨迹数据中统计路段被访问的时间分布, 统计每个路段在给定的 τ 个时段内的被访问时段, 得到被访问时间分布矩阵 $D \in \mathbb{R}^{N \times \tau}$. 然后使用余弦相似度计算各个路段在时间分布上的相似性矩阵, 即矩阵元素 c_{ij} 表示路段 r_i 和 r_j 间的时间模式余弦相似度, 可计算为

$$c_{ij} = \cos(\mathbf{v}_i^\tau, \mathbf{v}_j^\tau) \quad (3)$$

$$\mathbf{v}_k^\tau = \sum_{n=0}^{\tau-1} \sum_{t_n \in S_{r_k}} \mathbb{I}[t_m = t_n] \quad (4)$$

其中, \mathbf{v}_k^τ 表示路段 r_k 的被访问时间分布向量, 本文将时间戳离散化为 τ 个时段, t_n 为 τ 中的某个时段; S_{r_k} 表示路段 r_k 的被访问时段集; \mathbb{I} 为指示函数, 表示在时段 t_n 是否有访问记录. 本文设 τ 为 2 880, 将工作日的时间戳映射到一组 24×60 的时段 (0~1 439), 将周末的时间戳映射到另一组时段 (1 440~2 879).

4.1.2 E-RKG 的构建

为有效捕捉城市环境信息, 在 RKG 的基础上引入扩展知识图谱 E-RKG, 不仅考虑路段间的关系, 还对除道路之外的城市要素进行建模, 例如 POI、功能区等. 区别于传统城市知识图谱设计^[10], 本文参考最近研究^[12] 构建一个几何结构鲜明的知识图谱, 通过结构建模显著提升城市知识的表达能力. E-RKG 共提取 8 种实体, 分别是 Borough(administrative Borough)、Area(functional Area)、POI、Road(Road segment)、Junction(road Junction)、PC(POI Category)、RC(Road Category) 和 JC(Junction Category); 设计了 13 种关系, 涵盖地理包含、地理邻近及类别关联. 例如, 兴趣点位于区域 (POI Locates at Area, PLA) 和区域位于行政区 (Area Locates at Borough, ALB) 表示地理包含关系, 行政区邻近行政区 (Borough Nearby Borough, BNB) 反映地理邻近关系, 道路具有道路类别 (Road Has Road Category, RHRC) 则体现类别关联. 此构建策略展现了清晰的几何结构, 例如 RLA 和 ALB 能够有效表达城市空间的隶属关系, 体现层次结构; 而 BNB 通过地理邻近关系构建环形结构, 能够捕捉城市空间中的循环性关联. 对于捕捉影响移动交通行为的复杂空间关系至关重要. E-RKG 的关系详情如表 1 所示, 其中 RKG 建模的 4 种关系包括: RCR(Road Connectby Road)、RFR(Road FlowTransition Road)、RSR(Road Spatialsimilarity Road) 和 RTR(Road Timesimilarity Road), 分别是基于路段物理连接关系、历史轨迹的路段迁移关系、空间布局相似性关系以及时间模式相似性关系.

表 1 E-RKG 基本信息

缩写	头实体和尾实体	语义信息	缩写	头实体和尾实体	语义信息
RCR	(Road,Road)	Road Connectby Road	RFR	(Road,Road)	Road FlowTransition Road
RSR	(Road,Road)	Road SpatialSimilarity Road	RTR	(Road,Road)	Road TimeSimilarity Road
PLA	(POI, Area)	POI Locates at Area	JBR	(Junction, Borough)	Junction Belongs to Road
RLA	(Road, Area)	Road Locates at Area	BNB	(Borough, Borough)	Borough Nearby Borough
JLA	(Junction, Area)	Junction Locates at Area	ANA	(Area, Area)	Area Nearby Area
PBB	(POI, Borough)	POI Belongs to Borough	PHPC	(POI, PC)	POI Has POI Category
RBB	(Road, Borough)	Road Belongs to Borough	RHRC	(Road, RC)	Road Has Road Category
JBB	(Junction, Borough)	Junction Belongs to Borough	JHJC	(Junction, JC)	Junction Has Junction Category
ALB	(Area, Borough)	Area Locates at Borough			

4.2 知识图谱增强的轨迹嵌入

4.2.1 路段嵌入

为建模轨迹的时空语义,结合图编码器和时间编码器设计了时空嵌入模块.图编码器利用RKG,同时捕捉路段之间的局部和全局空间依赖关系,以获得全面的路段表示.具体的,首先对空间分布矩阵 \mathbf{P} 和时间分布矩阵 \mathbf{D} (见4.1.1节)进行归一化,得到 $\mathbf{P}_n \in \mathbb{R}^{N \times N^p}$ 和 $\mathbf{D}_n \in \mathbb{R}^{N \times N^t}$;其次,结合路段基本属性(如路段长度、宽度、最大速度限制和车道数等信息),按文献[1]的方法编码并拼接为路段属性矩阵 $\mathbf{X} \in \mathbb{R}^{N \times N^x}$,其中 N^x 表示路段的属性数量.最后,将 \mathbf{P}_n 、 \mathbf{D}_n 和 \mathbf{X} 投影并且拼接,生成嵌入维度为 d_r 的路段特征矩阵 $\mathbf{E}^{\text{fea}} \in \mathbb{R}^{N \times d_r}$,即

$$\mathbf{E}^{\text{fea}} = (\mathbf{P}_n \mathbf{W}_p \| \mathbf{D}_n \mathbf{W}_d \| \mathbf{X} \mathbf{W}_x) \quad (5)$$

其中, $\|$ 表示特征拼接操作.由于传统的图卷积网络或图注意力网络只能处理同构图,无法处理像知识图谱类的多关系异构图,因此本文采用R-GCN作为图编码器.R-GCN通过为每种关系类型分配不同的权重矩阵来处理异构图,即通过不同的关系分别聚合实体邻居的信息.在R-GCN中,每个节点 i 对应路段 r_i ,节点 i 的特征在第 l_r 层的更新式为

$$\mathbf{e}_i^{l_r} = \left(\sum_{r \in R_j \in N_{i,r}^l} \frac{1}{c_{i,r}^l} \mathbf{W}_r^{l_r-1} \mathbf{e}_j^{l_r-1} + \mathbf{W}_o^{l_r-1} \mathbf{e}_i^{l_r-1} \right) \quad (6)$$

其中, $N_{i,r}^l$ 表示关系 $r \in \mathbb{R}$ 下节点 i 的邻居路段集; $\mathbf{W}_r^{l_r-1} \in \mathbb{R}^{d^{(l_r)} \times d^{(l_r-1)}}$ 表示关系 r 的可学习参数; $\mathbf{e}_i^{l_r} \in \mathbb{R}^{d^{(l_r)}}$ 表示节点 i 在第 l_r 层的嵌入; $c_{i,r}^l$ 表示可以预先学习或选择的正则化常数; l_r 表示第 l_r 个R-GCN层,R-GCN以路段特征 \mathbf{E}^{fea} 和RKG为输入,生成富含道路语义信息的路段表示 $\mathbf{e}_i^{l_r}$.

4.2.2 时间嵌入

时间嵌入的目标是获得从时间域到 d_t 维向量空间的连续映射函数.现有嵌入方法忽略了人类移动行为的周期性信息,无法提取细粒度的时间特征.傅里叶变换以正弦和余弦函数为正交基,由于正弦和余弦函数

的周期性,使得它能够建模表达时间周期性(如一天中的时间).另外,傅里叶变换可以使用有限的参数来表示复杂的时间数据,因此在时间编码器中采用傅里叶变换对时间戳编码.对于时间戳 t_i ,其嵌入 $\mathbf{e}_i \in \mathbb{R}^d$ 的计算式为

$$\mathbf{e}_i = \sqrt{\frac{1}{d_t}} \left[\cos(\omega_1 t_i), \sin(\omega_1 t_i), \cos(\omega_2 t_i), \sin(\omega_2 t_i), \dots, \cos(\omega_{d_t} t_i), \sin(\omega_{d_t} t_i) \right] \quad (7)$$

其中, ω_k 表示第 k 个频率成分.

4.2.3 历史轨迹特征提取

受GPT的启发,本文采用Transformer解码器学习轨迹嵌入,其中的因果注意力机制能够确保模型仅关注历史位置信息,避免未来信息泄露.轨迹嵌入模块堆叠了 L_t 层Transformer解码器层,第 l 层的计算过程可描述如下:

$$\mathbf{q}_i = \mathbf{W}_q^l \mathbf{h}_i^{l-1}, \quad \mathbf{k}_i = \mathbf{W}_k^l \mathbf{h}_i^{l-1}, \quad \mathbf{v}_i = \mathbf{W}_v^l \mathbf{h}_i^{l-1} \quad (8)$$

$$a'_{i,j} = \frac{\exp\left(\frac{\mathbf{q}_i \cdot \mathbf{k}_j}{\sqrt{d_k}}\right)}{\sum_{j \leq i} \exp\left(\frac{\mathbf{q}_i \cdot \mathbf{k}_j}{\sqrt{d_k}}\right)} \quad (9)$$

$$\mathbf{z}_i = \text{MultiHead} \left(\sum_{j \leq i} a'_{i,j} \mathbf{v}_j \right) \mathbf{W}_o \quad (10)$$

$$\bar{\mathbf{h}}_i = \text{LayerNorm}(\mathbf{h}_i^{l-1} + \mathbf{z}_i) \quad (11)$$

$$\mathbf{h}_i^l = \text{LayerNorm}(\text{FFN}(\bar{\mathbf{h}}_i)) \quad (12)$$

其中, $\mathbf{h}_i^{l-1} \in \mathbb{R}^d$ 表示上一层(即第 $l-1$ 层)的隐藏表示,当 $l=1$ 时,即 $\mathbf{h}_i^0 = (\mathbf{e}_i^{l_r} \| \mathbf{e}_i^{l_t}) + \mathbf{e}_{\text{pos}}$, $\mathbf{e}_i^{l_r}$ 表示路段嵌入, $\mathbf{e}_i^{l_t}$ 为时间嵌入, \mathbf{e}_{pos} 表示位置编码; \mathbf{W}_q^l 、 \mathbf{W}_k^l 、 \mathbf{W}_v^l 、 $\mathbf{W}_o \in \mathbb{R}^{d \times d}$ 表示要学习的参数矩阵; d_k 表示键向量 \mathbf{k}_j 的维度; $a'_{i,j}$ 表示当前路段 r_i 与历史路段 r_j 的归一化注意力分数;FFN表示前馈神经网络(Feed Forward neural Network, FFN).由于模型仅考虑已经观察到的历史位置信息,所以只计算当前路段 r_i 的查询向量 \mathbf{q}_i 与其自身及之前所有

键向量 \mathbf{k}_j 之间的点积,得到的注意力分数矩阵是三角矩阵.

4.2.4 环境知识捕获

考虑到城市环境对于轨迹生成的影响,引入 E-RKG 进行环境知识提取. 为捕捉复杂的结构特性以及环境特征,采用结构感知的 GIE 知识图谱嵌入方法^[12] 从 E-RKG 中提取特征. GIE 能够同时处理欧式空间、双曲空间和超球面空间中的嵌入,其得分函数的定义为

$$\phi(h, r, t) = -\left(d_c(\text{Inter}(\mathbf{E}_h, \mathbf{H}_h, \mathbf{S}_h), t)\right) + d_c(\text{Inter}(\mathbf{E}_t, \mathbf{H}_t, \mathbf{S}_t), h) + b_1 \quad (13)$$

其中, $\mathbf{E}_h, \mathbf{E}_t \in \mathbb{R}^d$, $\mathbf{H}_h, \mathbf{H}_t \in \mathbb{R}^{d_h}$ 和 $\mathbf{S}_h, \mathbf{S}_t \in \mathbb{R}^{d_s}$ 分别表示头实体和尾实体在欧式空间、双曲空间和超球面空间中的嵌入表示; $\text{Inter}(\cdot)$ 函数表示空间交互过程,用于整合来自不同空间的几何信息; $d_c(\cdot)$ 表示距离函数; b_1 表示偏置项. GIE 模型的目标是最小化不存在于知识图谱的三元组的得分,同时最大化存在于知识图谱中的三元组得分,从而使得实体嵌入能够准确反映知识图谱中蕴含的城市环境知识.

首先,通过 GIE 模型预训练获得所有实体的嵌入表示向量 $\mathbf{E}^{\text{pre}} \in \mathbb{R}^{N_e \times d_e}$, 其中 N_e 表示 E-RKG 中的实体数量, d_e 为实体嵌入维度. 然后,使用 R-GCN 进一步优化预训练的实体嵌入,以 \mathbf{E}^{pre} 作为输入,输出优化后的环境知识嵌入 $\mathbf{E}^{\text{en}} \in \mathbb{R}^{N \times d}$.

4.2.5 特征融合

为生成环境感知的轨迹嵌入 $\mathbf{h}_i^{\text{en}} \in \mathbb{R}^d$, 设计了一个特征融合模块,融合过程可描述为

$$\mathbf{h}_i^{\text{en}} = \sigma(\mathbf{W}_i \mathbf{h}_i^l + \mathbf{W}_e \mathbf{e}_i^{\text{en}} + \mathbf{b}_2) \quad (14)$$

其中, σ 表示非线性激活函数 GELU; $\mathbf{W}_i, \mathbf{W}_e \in \mathbb{R}^{d \times d}$ 表示可学习参数; \mathbf{h}_i^l 来自式(12), 表示路段 r_i 的嵌入表示向量; $\mathbf{e}_i^{\text{en}} \in \mathbb{R}^d$ 来自 \mathbf{E}^{en} , 表示融入环境知识的路段嵌入向量. 这样可成功地将城市环境特征融入轨迹表示,为下一步预测任务提供更丰富的信息.

4.3 轨迹预测

轨迹数据由时间信息和空间信息构成,考虑到它们的差异性,将轨迹预测模块分解为路段预测和时间戳预测两个子模块.

首先,路段的预测. 通过对环境感知的轨迹嵌入 \mathbf{h}_i^{en} 并经过 Linear 线性层和 Softmax 处理,得到下一条路段的概率分布 $\hat{\mathbf{y}}_{i+1} \in \mathbb{R}^V$. 其中, $\text{Mask}(\cdot)$ 表示利用路网邻接矩阵避免生成不连续路段,以确保轨迹生成的连续性.

$$\hat{\mathbf{y}}_{i+1} = \text{Softmax}(\text{Mask}(\text{Linear}(\mathbf{h}_i^{\text{en}}))) \quad (15)$$

然后,时间戳预测. 将时间戳预测问题转化为行驶时间预测 $d_{i+1} = t_{i+1} - t_i$, 基于当前时间戳 t_i 和预测的行驶时间 d_{i+1} , 可直接推导出下一时间戳 t_{i+1} . 与路段预测类似,基于 \mathbf{h}_i^{en} 使用另一个线性层预测:

$$\hat{d}_{i+1} = \text{Mask}(\text{Linear}(\mathbf{h}_i^{\text{en}})) \quad (16)$$

4.4 损失函数

轨迹数据的时间和空间信息存在差异性,但具有内在关联性. 为有效建模这种时空耦合关系,将总损失函数设计为路段预测损失与行驶时间预测损失的加权组合,计算式为

$$\mathcal{L} = \alpha \cdot \mathcal{L}_r + \beta \cdot \mathcal{L}_d \quad (17)$$

其中, \mathcal{L}_r 表示路段预测的多分类交叉熵损失; \mathcal{L}_d 表示行驶时间预测的均方误差损失; α 和 β 表示权重系数,在本文中均设为 1.

首先,对于路段预测任务,本文将其视为一个多分类问题,使用多分类交叉熵损失进行优化,即

$$\mathcal{L}_r = -\frac{1}{ML} \sum_{m=1}^M \sum_{i=1}^{L-1} \mathbf{y}_{i+1}^m \cdot \ln(\hat{\mathbf{y}}_{i+1}^m) \quad (18)$$

其中, M 表示移动轨迹的数量; L 表示每条轨迹的长度; $\hat{\mathbf{y}}_{i+1}^m = f(\mathbf{y}_{1:i}^m)$ 表示由模型 f 预测的路段概率分布.

然后,对于行驶时间预测任务,本文将其视为一个回归问题,使用均方误差损失函数进行优化,即

$$\mathcal{L}_d = -\frac{1}{ML} \sum_{m=1}^M \sum_{i=1}^{L-1} (d_{i+1}^m - \hat{d}_{i+1}^m)^2 \quad (19)$$

其中, $\hat{d}_{i+1}^m = f(d_{1:i}^m)$ 表示模型预测的行驶时间.

4.5 轨迹生成

轨迹生成的目标是基于真实分布特征生成高质量的轨迹,为此,本文从训练集的统计先验中采样起点 r_1 和开始时间戳 t_1 . 值得注意的是,在本文的设定中,轨迹无须到达特定的目的地,因为每个生成的轨迹具有固定的长度限制. 模型以 RKG、E-RKG、GIE 预训练得到的实体嵌入 \mathbf{E}^{pre} , 轨迹起点 r_1 和开始时间戳 t_1 作为输入,采用温度采样策略^[18], 自回归式生成移动轨迹,具体过程见算法 1.

5 实验

5.1 实验设置

5.1.1 数据集

采用两个真实轨迹数据集来衡量所提出模型的性能:(1)BJ-Taxi,出租车 GPS 轨迹数据集,涵盖北京市四环路以内的区域,采集时间从 2015 年 11 月 1 日至 7 日,采样频率为 1 min;(2)Porto-Taxi, Kaggel 轨迹预测竞赛发布的波尔图市出租车 GPS 轨迹数据集,采集时间从 2013 年 7 月 1 日至 2014 年 7 月 1 日,采样频率为 15 s.

本文将 GPS 轨迹转为路段轨迹^[11],并按 7:1:2 的比例随机划分为训练集、验证集和测试集. 构建 E-RKG 的数据从 Open Street Map 网站获取,包括路网数据、POI 数据及行政区划数据. 为避免长尾问题,合并少数的 POI 类别^[12]. 轨迹数据集和 E-RKG 的具体信息如表 2 所示.

算法 1 轨迹生成过程

输入: RKG、E-RKG 预训练得到的实体嵌入 E^{pre} , 轨迹起点 r_1 和开始时间戳 t_1

输出: 一条合成路段轨迹 $\hat{x} = [\hat{p}_1, \hat{p}_2, \dots, \hat{p}_n]$ 满足 $\hat{p}_1 = (r_1, t_1)$

1. 从训练集的统计先验中采样起点 r_1 和开始时间戳 t_1
2. 初始化轨迹 $\hat{x} = [(r_1, t_1)]$
3. FOR $i=1$ to $L-1$ DO:
4. $e_i^l \leftarrow \text{GraphEncoder}(E^{pre}, \text{RKG})$ // 图编码器算路段嵌入
5. $e_i \leftarrow \text{TimeEncoder}(t_i)$ // 时间编码器计算时间嵌入
6. $h_i = (e_i^l \parallel e_i)$ // 拼接得到初始嵌入
7. $h_i^l \leftarrow \text{TransformerDecoder}(h_1, h_2, \dots, h_i)$ // 计算轨迹嵌入
8. $e_i^{en} \leftarrow \text{RGCN}(E^{pre}, \text{E-RKG})$ // 用 RGCN 优化实体嵌入
9. $h_i^{en} \leftarrow \text{MLP}(h_i^l, e_i^{en})$ // 融合得到环境感知的轨迹嵌入
10. 基于 h_i^{en} 使用两个线性层分别预测 \hat{r}_{i+1} 和 \hat{t}_{i+1}
11. 将 $(\hat{r}_{i+1}, \hat{t}_{i+1})$ 添加到轨迹 \hat{x} 中
12. END FOR
13. RETURN \hat{x}

表 2 两个真实轨迹数据集的基本信息和 E-RKG 基本统计数据

数据集	轨迹数据集基本信息			E-RKG 统计数据		
	出租车 辆数	道路 条数	轨迹 数量	实体 数量	关系 数量	事实 数量
BJ-Taxi	15 642	37 684	953 672	146 465	17	794 366
Porto-Taxi	435	10 904	694 528	22 976	17	174 496

5.1.2 基线模型

为验证 KG-TrajGen 模型的性能, 本文将其与以下基线模型进行对比: (1) Semi-Markov (半马尔可夫)^[19] 在马尔可夫模型的基础上引入时间的概念; (2) 序列生成对抗网络 (Sequence Generative Adversarial Networks, SeqGAN)^[20] 将序列生成视为强化学习过程用判别器提供奖励信号, 通过策略梯度训练生成器; (3) 长短期记忆 (Long Short-Term Memory, LSTM) 网络^[21], 使用 LSTM 网络直接预测下一个位置和行驶时间, 预测结果作为合成轨迹; (4) 序列变分自编码器 (Sequential Variational AutoEncoder, SVAE)^[22] 将 VAE 和 Sequence-to-Sequence 模型相结合, 用于人类移动轨迹模拟; (5) MoveSim^[2] 是基于 GAN 的轨迹生成方法, 融合了人类移动规律的先验知识; (6) LSTM 轨迹生成对抗网络 (Long Short-Term Memory Trajectory Generative Adversarial Networks, LSTM-TrajGAN)^[23] 将轨迹的空间、时间和语义信息进行编码, 设计了融合 LSTM 等神经网络结构的轨迹生成器和轨迹判别器; (7) 端到端轨迹生成 (End-to-End Trajectory Generation, EETG)^[24] 是基于 VAE 的方法, 结合 VAE 和变分循环神经网络对轨迹进行编码, 用 LSTM 生成轨迹; (8) TS-TrajGen^[1] 采用两阶段的生成过程, 以解决现有随机生成过程中的误差累积问题, 即先生成粗粒度的区域轨迹, 再在区域轨迹的引导下生成路段轨

迹; (9) 基于扩散的轨迹生成 (Diffusion-based Trajectory generation, DiffTraj)^[17] 是生成 GPS 轨迹的时空扩散概率模型; (10) 可控轨迹生成 (Controllable Trajectory generation, ControlTraj)^[25] 结合路网拓扑结构约束来生成高质量的 GPS 轨迹; (11) 用户画像引导的潜在扩散 (User Profile-Guided Latent Diffusion, UPGLD)^[26] 是一种面向离散轨迹数据的潜在扩散建模框架, 通过在连续潜在表示与离散位置索引之间引入可学习的嵌入与映射机制, 能有效建模离散空间结构; (12) STEGA^[11] 结合时空语义和语义感知图技术以生成高质量的路段轨迹。

5.1.3 评价指标

为全面评估合成轨迹的质量, 本文采用 3 类常用指标, 即统计特征误差、频繁模式特征误差和轨迹误差。其中统计特征误差专注于整体分布特征, 频繁模式特征误差挖掘隐藏在轨迹数据背后的移动模式, 轨迹误差则用于量化合成轨迹与真实轨迹之间的相似性。

统计特征误差是指合成轨迹与真实轨迹的统计特征的差异^[1, 18, 27], 具体的统计特征包括:

(1) Distance: 表示轨迹中相邻路段 r_i 与 r_{i+1} 之间的空间移动距离, 定义为 $\text{Dis}(r_i, r_{i+1})$, $\text{Dis}(\cdot)$ 表示欧式距离。

(2) Radius: 个体轨迹的回旋半径, 定义为轨迹中每个路段 r_i 到轨迹中心点 r_c 的平均距离, 即 $\frac{1}{L} \sum_{i=1}^L \text{Dis}(r_i, r_c)$, 其中 L 为轨迹长度。

(3) Frequency: 城市道路的空间分布, 对于路网中的任意路段 r_k , 每个路段的访问次数可计算为 $\sum_{m=1}^M \sum_{i=1}^L \mathbb{I}[r_i = r_k]$, 表示路段 r_k 是否有访问记录。

(4) RQuery (Road Query error): 路网中轨迹的随机查询。通过从路网中随机抽样 500 条路段, 计算该路段的真实轨迹数量和合成轨迹数量之间的标准化绝对差。误差公式定义为

$$\text{RQuery} = \frac{Q(x) - Q(\hat{x})}{\max\{Q(x), s\}} \quad (20)$$

其中, $Q(x)$ 和 $Q(\hat{x})$ 分别表示来自真实轨迹和合成轨迹的查询结果; s 表示一个下界, 设为轨迹数量的 1%。

(5) Duration: 计算相邻路段的行驶时间 $d_{i+1} = t_{i+1} - t_i$, 反映轨迹的时间特征。

使用 Jensen-Shannon 散度 (JSD) 量化真实轨迹与生成轨迹之间的 Distance、Radius、Frequency 和 Duration 分布差异, JSD 的计算式为

$$\text{JSD}(p, q) = \frac{1}{2} \text{KL}\left(p \parallel \frac{p+q}{2}\right) + \frac{1}{2} \text{KL}\left(q \parallel \frac{p+q}{2}\right) \quad (21)$$

其中, p 和 q 表示两个分布; $\text{KL}(\cdot \parallel \cdot)$ 表示 Kullback-Leibler 散度。JSD 值越小, 表示生成轨迹与真实轨迹的

时空分布越接近。

频繁模式特征误差是指合成轨迹的频繁模式与真实轨迹的频繁模式特征的差异^[3]:

(1)IFPattern(Inverse F_1 Pattern):评估高频模式集的差异,模式 P 定义为连续网格单元的有序序列,本文选择真实轨迹数据集和合成轨迹数据集中出现次数最多的前 n 个模式,分别表示为 FP 和 FP_{syn} , n 设置为 500,具体式为

$$\begin{aligned} & \text{IFPattern} \\ &= 1 - 2 \times \frac{\text{Precision}(FP, FP_{syn}) \times \text{Recall}(FP, FP_{syn})}{\text{Precision}(FP, FP_{syn}) + \text{Recall}(FP, FP_{syn})} \end{aligned} \quad (22)$$

(2)PEError(Pattern Error):衡量模式出现次数的相对差异。

$$\text{PEError} = \frac{1}{|FP|} \sum_{P \in FP} \frac{|n^P - n_{syn}^P|}{n^P} \quad (23)$$

其中, n^P 和 n_{syn}^P 分别表示模式 P 在 FP 和 FP_{syn} 的出现次数。

轨迹误差采用距离来衡量,即合成轨迹与真实轨迹的距离^[1,11]。一条真实轨迹的轨迹误差定义为它与所有合成轨迹的距离的最小值。整个轨迹数据集的轨迹误差定义为该轨迹数据集中所有真实轨迹的平均轨迹误差:

$$\text{Trajectory Error} = \frac{1}{M} \sum_{x \in T, \hat{x} \in \hat{T}} \text{SeqDist}(x, \hat{x}) \quad (24)$$

其中,SeqDist为距离计算方法,可采用Hausdorff距离或Fréchet距离,相较于Hausdorff距离考虑了沿轨迹的点的位置和顺序。

此外,训练总轮数为 50,批量大小为 32,并在训练期间采用早停策略以防止过拟合,选择 Adam 优化器,初始学习率设为 5×10^{-4} 。RGCN 层数、E-RKG 的实体嵌入维度、Trasformer 层数和温度系数分别从 $\{1, 2, 3\}$ 、 $\{16, 32, 64, 128\}$ 、 $\{1, 2, 3\}$ 和 $\{0.2, 0.4, 0.6, 0.8, 1.0, 1.2, 1.4\}$ 中搜索,以确定最佳配置。所有实验结果均在 NVIDIA RTX 4090 平台上运行得到。

5.2 总体性能

5.2.1 定量分析

表 3 展示了本文模型与基线模型在统计特征误差、频繁模式特征误差和轨迹误差 3 类指标上的实验结果。所有指标越低越好,最佳结果以粗体显示,次佳结果以下划线显示,“—”表示对应的模型无法生成时间信息。结果表明:本文的 KG-TrajGen 模型的三类指标均显著优于所有基线方法。

在统计特征误差方面,与次优模型相比,KG-TrajGen 在 BJ-Taxi 数据集上将 Distance、Frequency 和 RQuery 分别提高了 32.6%、3.4% 和 3.6%,在 Porto-Taxi 数据集上分

别提高了 36.4%、13.8% 和 14.2%。这是因为 KG-TrajGen 通过融入城市环境信息,生成了更真实的轨迹。值得注意的是,STEGA 在 BJ-Taxi 数据集上表现突出,得益于其时空门控机制能动态捕捉交通轨迹变化。而在 Porto-Taxi 数据集中,Semi-Markov 展现了较优的性能,这是因为 Porto 市路网规模较小,使得它能够较好地拟合空间分布特征。相比之下,未考虑路网的模型(如 MoveSim)生成的轨迹与真实轨迹的整体分布特征的差异较大。

在频繁模式特征误差方面,KG-TrajGen 由于引入了考虑局部和全局依赖关系的 RKG,能更准确地捕捉人类移动模式,从而实现了较低的频繁模式特征误差。相比之下,其他基线模型未能充分考虑全局空间依赖关系,导致它们表现较差。

在轨迹误差方面,由于城市环境中的 POI 或区域功能等信息深刻影响着个体的移动意图,因此使用富含城市环境信息的 E-RKG 的 KG-TrajGen,在模拟个体的移动轨迹方面展现了明显的优势。此外,融入条件信息的 DiffTraj 和集成路网拓扑约束的 ControlTraj 也展现了较好的性能。

5.2.2 可视化分析

为更直观地展示生成轨迹的质量,对比了 5 个表现较好的模型在 Porto-Taxi 数据集上的轨迹分布热力图,如图 3 所示。总体上,所有模型均能大致捕捉轨迹的空间分布特征,但 KG-TrajGen 生成的数据在空间分布上表现出最高的相似性,而其他模型都存在显著差异,例如 Semi-Markov 倾向于生成高频访问区域的轨迹序列,导致对郊区等低频区域的覆盖不足,Ts-TrajGen 则利用 A* 搜索来生成下一位置,从而获得更加广泛的访问地点,此外,DiffTraj 由于未考虑路网拓扑约束,容易生成不合理的轨迹。

5.3 消融实验

5.3.1 RKG 和 E-RKG 对模型性能的影响分析

为验证 RKG 和 E-RKG 对模型的贡献,设计 4 种变体进行消融实验:(1)“w/o RKG”,移除 RKG,利用 GAT 从路网拓扑结构中学习路段表示,即仅考虑局部空间依赖关系;(2)“w/o E-RKG”,移除 E-RKG,不融入城市环境信息;(3)“w/o RKG(E-RKG@SPEmb)”,移除 RKG,并将 E-RKG 环境知识嵌入的位置下移到更底层的时空嵌入层代替 RKG 学习路段表示;(4)“w/o all”,同时移除 RKG 和 E-RKG。实验结果如图 4 所示,其中“our model”是指 KG-TrajGen 模型,由图 4 可知,KG-TrajGen 几乎在所有指标上取得最优性能,同时移除 RKG 和 E-RKG 的变体模型(即“w/o all”)表现最差,这充分验证了 RKG 和 E-RKG 对模型性能提升的贡献。此外,“w/o RKG”变体在大部分指标上优于“w/o E-RKG”变体,这说明 E-RKG 比 RKG 对模型性能的影响更显著,尤其是统计特征误

表 3 KG-TrajGen 与基线模型在 BJ-Taxi 数据集和 Porto-Taxi 数据集上的对比实验

数据集	模型	统计特征误差					频繁模式特征误差		轨迹误差	
		Distance	Radius	Frequency	RQuery	Duration	IFPattern	PErrror	Hausdorff	Fréchet
BJ-Taxi	Semi-Markov	0.004 7	0.039 1	0.065 3	0.035 8	0.004 6	0.222	0.214	1.954	2.333
	SeqGAN	0.117 8	0.059 7	0.143 3	0.039 0	—	0.498	0.837	5.557	6.165
	LSTM	0.012 0	0.102 3	0.093 1	0.043 5	0.014 7	0.280	0.272	3.671	4.180
	SVAE	0.057 7	0.030 8	0.335 7	0.080 7	—	0.326	0.512	1.901	2.229
	MoveSim	0.565 9	0.318 2	0.427 6	0.069 0	—	0.880	0.957	7.986	9.095
	LSTM-TrajGAN	0.189 3	0.054 8	0.447 7	0.093 5	—	0.736	0.729	2.617	3.033
	EETG	0.057 3	0.032 5	0.329 9	0.082 7	—	0.330	0.508	1.892	2.213
	TS-TrajGen	0.015 6	<u>0.030 6</u>	0.171 6	0.075 7	0.001 1	0.372	0.429	2.096	2.429
	DiffTraj	0.115 0	0.051 3	0.364 7	0.084 3	0.024 0	0.346	0.430	2.005	2.366
	ControlTraj	0.069 1	0.030 9	0.293 1	0.077 6	0.021 7	0.232	0.287	1.742	2.105
	UPGLD	0.009 2	0.044 1	0.070 3	0.036 2	—	0.244	0.285	2.448	2.862
	STEGA	<u>0.004 3</u>	0.036 9	<u>0.058 7</u>	<u>0.033 6</u>	0.003 3	<u>0.174</u>	<u>0.206</u>	2.043	2.388
	KG-TrajGen(Ours)	0.002 9	0.029 6	0.056 7	0.032 4	<u>0.003 3</u>	0.170	0.194	<u>1.853</u>	<u>2.191</u>
Porto-Taxi	Semi-Markov	<u>0.002 2</u>	0.051 6	<u>0.018 9</u>	<u>0.070 2</u>	0.000 8	<u>0.123</u>	<u>0.123</u>	0.875	1.035
	SeqGAN	0.116 6	0.065 0	0.092 3	0.159 1	—	0.483	0.446	1.147	1.374
	LSTM	0.025 8	0.087 2	0.073 7	0.144 7	0.040 6	0.347	0.417	1.215	1.458
	SVAE	0.100 6	0.035 7	0.250 4	0.243 9	—	0.367	0.549	0.839	3.651
	MoveSim	0.598 6	0.227 0	0.450 0	0.229 3	—	0.763	1.273	1.497	1.711
	LSTM-TrajGAN	0.190 3	0.037 1	0.321 6	0.289 3	—	0.657	0.713	0.959	1.111
	EETG	0.169 3	0.037 8	0.265 1	0.241 1	—	0.333	0.417	0.849	0.983
	TS-TrajGen	0.027 0	0.033 9	0.151 6	0.245 0	0.002 9	0.503	0.556	0.904	1.011
	DiffTraj	0.128 7	<u>0.032 0</u>	0.213 5	0.238 0	0.004 7	0.237	0.267	<u>0.834</u>	<u>0.943</u>
	ControlTraj	0.113 0	0.033 0	0.246 0	0.251 3	0.002 2	0.257	0.263	0.929	1.081
	UPGLD	0.004 6	0.039 7	0.020 9	0.073 6	—	0.207	0.255	0.881	1.015
	STEGA	0.003 5	0.034 9	0.022 1	0.071 1	0.001 0	0.207	0.141	0.869	0.975
	KG-TrajGen(Ours)	0.001 4	0.031 2	0.016 3	0.060 2	<u>0.001 0</u>	0.107	0.100	0.812	0.920

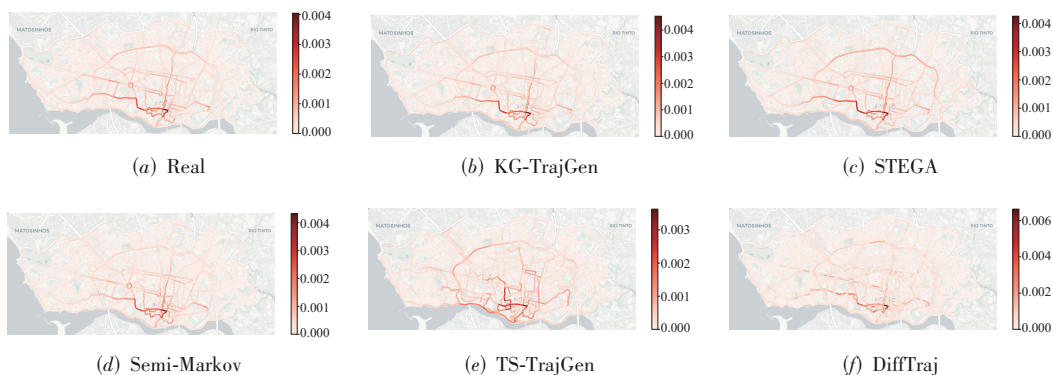


图 3 Porto-Taxi 数据集上真实和合成轨迹的轨迹分布的地理可视化

差方面(如 Distance、Frequency、RQuery 等)明显变差,表明 E-RKG 的贡献度比 RKG 更大.最后,在轨迹误差方面(如 Fréchet 距离),KG-TrajGen 的表现略逊于“w/o RKG(E-RKG@SPEmb)”变体[见图 4(h)和图 4(i)],但在其他指标上均优于该变体.其原因可能是当 E-RKG 被下移到时空嵌入层时,环境信息与轨迹紧密耦合,能

够更精细地引导轨迹点的局部生成过程,从而在几何路径拟合上更具优势.然而,这种设计也可能因 E-RKG 结构复杂而引入噪声,对模型训练产生负面影响.相比之下,KG-TrajGen 将环境信息在更高层的特征融合层面进行知识整合,更有利于捕捉宏观移动模式和统计规律,使其他指标表现更优.

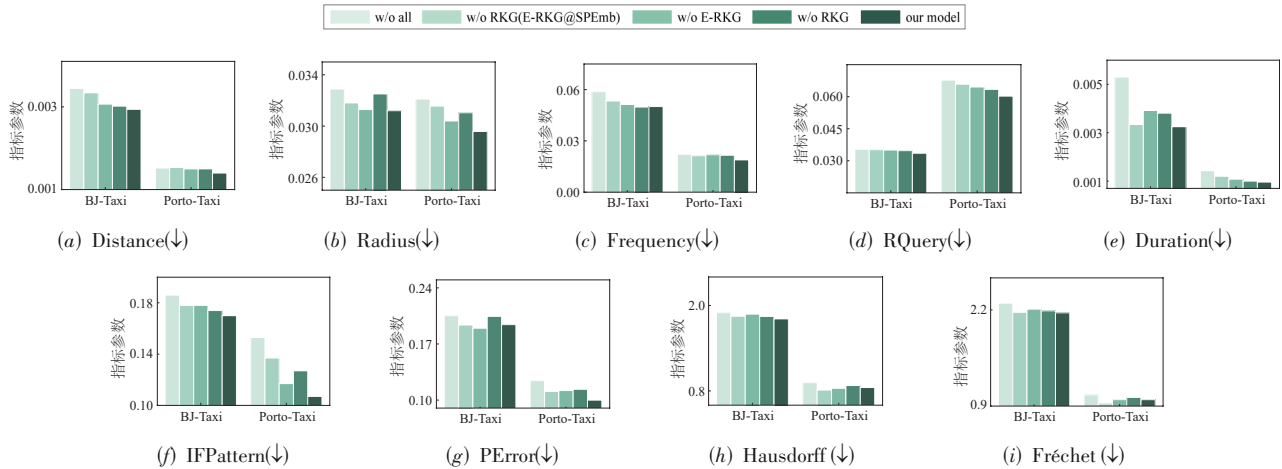


图4 两个真实世界数据集的消融实验结果

5.3.2 不同复杂度城市知识图谱对模型性能的影响分析

为探讨不同复杂度城市知识图谱对模型性能提升的差异,本文对E-RKG进行消融实验,设计了3种变体:(1)“w/o Area”,移除Area(即功能区)实体及其关联的所有关系;(2)“w/o Borough”,移除Borough(即行政区)实体及其关联的所有关系;(3)“w/o POI”,移除POI实体及其关联的所有关系.由表4可知,完整的知识图谱效果更优.进一步发现,移除Area实体(即“w/o Area”)和

Borough实体(即“w/o Borough”)这种区域信息会导致模型性能下降,表明宏观空间语义对生成轨迹的整体结构与移动规律具有关键引导作用.相比之下,移除POI实体(即“w/o POI”)带来的性能损失相对较小,可能是因为POI提供的多为细粒度、局部的地理信息,影响范围有限.此外,即使在部分城市环境数据缺失的情况下,模型性能虽然有一定下降,但大部分指标仍优于基线方法,证明本方法在某些城市环境数据缺失的场景下仍然具备较强的实用性.其中,最佳结果以粗体显示,次佳结果以下划线显示.

表4 KG-TrajGen在BJ-Taxi数据集和Porto-Taxi数据集上的城市知识图谱消融实验

数据集	模型	统计特征误差					频繁模式特征误差		轨迹误差	
		Distance	Radius	Frequency	RQuery	Duration	IFPattern	PError	Hausdorff	Fréchet
BJ-Taxi	w/o Area	0.003 2	0.033 2	0.058 4	0.033 6	0.004 6	0.170	0.200	1.917	2.274
	w/o Borough	0.003 2	0.033 2	0.057 6	<u>0.033 4</u>	0.002 8	0.182	<u>0.19 8</u>	1.876	2.223
	w/o POI	<u>0.003 1</u>	<u>0.032 5</u>	<u>0.057 1</u>	0.033 7	<u>0.003 0</u>	<u>0.17 6</u>	0.202	<u>1.871</u>	<u>2.211</u>
	KG-TrajGen(Ours)	0.002 9	0.029 6	0.0567	0.032 4	0.003 3	0.170	0.194	1.853	2.191
Porto-Taxi	w/o Area	<u>0.001 5</u>	0.032 3	<u>0.017 4</u>	0.061 9	<u>0.001 1</u>	0.114	0.110	0.817	0.929
	w/o Borough	<u>0.001 5</u>	0.032 3	0.017 5	0.060 5	0.001 0	0.117	<u>0.101</u>	0.814	0.923
	w/o POI	0.001 4	<u>0.031 3</u>	<u>0.017 4</u>	<u>0.060 4</u>	0.001 0	<u>0.113</u>	<u>0.101</u>	0.811	0.918
	KG-TrajGen(Ours)	0.001 4	0.031 2	0.016 3	0.060 2	0.001 0	0.107	0.100	<u>0.812</u>	<u>0.920</u>

5.4 E-RKG 的有效性实验

为验证从E-RKG学习到的嵌入向量是否包含城市环境信息,本文进行了道路所属功能分类实验.将E-RKG中道路的嵌入向量(road Embeddings in E-RKG,E-RKGE)与随机初始化的道路嵌入向量(Randomly initialized road embeddings,Random)进行对比,以评估两者在分类任务上的表现.考虑到周边城市功能区,道路可分为7类:商业、教育、工业、自然、公共、居住和交通.随后,真实数据集以5:5的比例分为训练集和测试集,并在训练集上分别使用K-近邻(K-Nearest Neighbors,KNN)、随机森林(Random Forest,RF)、MLP和支持向量

机(Support Vector Machine,SVM)4种分类器进行训练,最终在测试集上以准确率评估性能.由表5可知,使用E-RKGE的大多数分类结果准确率超过了60%,在北京数据集上的表现尤为突出,达到了80%以上.这表明学到的E-RKGE确实包含有关城市功能区的信息,例如其城市功能类型.此外,E-RKGE还可能包含其他类型的城市环境信息,相比之下,使用Random的分类结果明显较差,进一步证实E-RKG蕴含丰富的城市环境信息.

5.5 少样本实验

由于真实轨迹数据的稀缺性,模型在少样本场景下的轨迹生成能力至关重要.因此,本文在两个真实轨

表5 E-RKG有效性实验结果

方法	北京		波尔图	
	Random	E-RKGE	Random	E-RKGE
KNN	0.521	0.837	0.176	0.676
RF	0.565	0.850	0.209	0.696
MLP	0.533	0.809	0.194	0.611
SVM	0.569	0.809	0.216	0.576

迹数据集上展开实验,以评估模型在不同训练数据规模下的表现. 本文随机选取0.5万条、1万条、2.5万条、5万条和10万条轨迹进行训练,并比较其生成轨迹的质量. 如图5所示,“Full”表示使用完整训练集(BJ-Taxi为667 570条,Porto-Taxi为486 169条)的结果. 实验结果表明:仅用0.5万条训练数据,KG-TrajGen仍能生成高质量轨迹,这得益于模型有效融合了多源城市环境信息. 此外,随着训练数据的增加,生成质量呈现稳步提升趋势,进一步验证了模型在少样本场景下的鲁棒性与可扩展性.

5.6 下游任务实验

本文采用下游任务交通流量预测来验证KG-TrajGen模型生成轨迹数据的实用性. 将城市划分为 16×16 的网格(即区域),预测某一时段各区域的交通流量. 实验使用真实轨迹数据和基于不同基线生成的轨迹数据训练多个高级预测模型^[28-30],使用平均绝对误差(Mean Absolute Error, MAE),平均百分比误差(Mean Average Percentage Error, MAPE)和均方根误差(Rooted Mean Square Error, RMSE)来衡量预测精度. 如表6所示,除

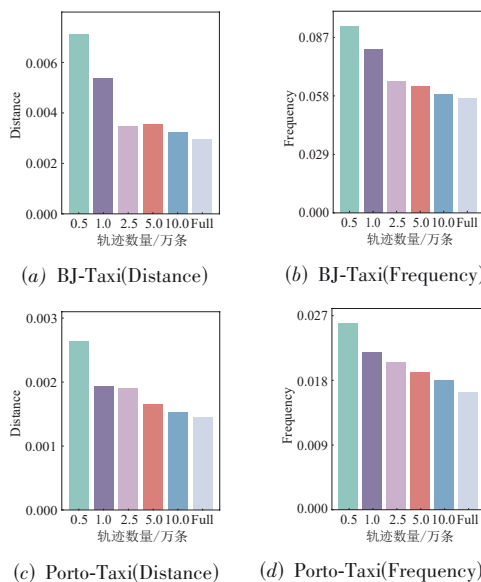


图5 KG-TrajGen在两个真实世界数据集的少样本实验

使用真实数据(Real)训练的结果外,最佳结果用粗体标注,可见KG-TrajGen生成轨迹数据的预测结果更接近真实数据,表明其生成的轨迹相较于其他模型保留了更多的交通流量分析所需的时间和空间分布特征. 例如,在Porto-Taxi数据集上,KG-TrajGen生成的数据与真实数据训练AGCRN模型的表现几乎一致,而其他基线生成模型则存在显著差异. 结果表明:KG-TrajGen生成的轨迹能更适用于复杂预测任务,进一步验证了模型的优越性和实用性. 其中,最佳结果以粗体显示.

表6 BJ-Taxi和Porto-Taxi数据集的交通流量预测对比实验

数据集	模型	GRU			STNN			AGCRN		
		MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE
BJ-Taxi	Real	1.660	0.784	2.195	1.671	0.646	2.254	1.519	0.831	2.017
	TS-TrajGen	1.880	1.058	2.348	1.887	0.556	2.648	1.516	0.814	2.043
	DiffTraj	1.960	1.130	2.427	1.811	0.566	2.533	1.829	1.041	2.359
	ControlTraj	1.871	0.987	2.236	1.801	0.576	2.511	1.654	0.987	2.228
	STEGA	1.683	0.844	2.189	1.833	0.731	2.425	1.553	0.846	2.079
	KG-TrajGen(Ours)	1.682	0.783	2.228	1.623	0.675	2.163	1.464	0.810	1.939
Porto-Taxi	Real	2.201	0.535	3.313	2.548	0.607	3.772	2.094	0.513	3.080
	TS-TrajGen	3.261	0.837	4.803	3.062	0.726	4.488	2.416	0.636	3.461
	DiffTraj	2.387	0.613	3.620	2.590	0.647	3.876	2.142	0.554	3.160
	ControlTraj	2.348	0.610	3.537	2.572	0.658	3.818	2.142	0.550	3.165
	STEGA	2.326	0.539	3.526	2.546	0.592	3.778	2.124	0.516	3.133
	KG-TrajGen(Ours)	2.252	0.490	3.461	2.496	0.549	3.698	2.096	0.485	3.105

5.7 超参数实验

进一步探讨超参数设置对KG-TrajGen在BJ-Taxi和Porto-Taxi数据集上生成轨迹性能的影响.

(1)分析R-GCN层数对轨迹生成的影响,层数取值范围为 $\{1, 2, 3\}$. 如图6(a)所示,使用两层R-GCN对

RKG建模效果最佳,层数少使得模型无法完全捕捉道路间的复杂空间依赖关系,层数增加会导致过平滑问题,失去区分不同道路的能力.

(2)考察实体嵌入维度对轨迹生成的影响,取值范围为 $\{16, 32, 64, 128\}$. 如图6(b)所示,32维嵌入从总体

上达到了较好的效果,较低维度的嵌入限制了模型表达能力,无法有效表示周围的复杂环境;而过高维度的嵌入虽然增加了模型的表达能力,但也可能引入不必要的噪声。

(3)分析 Transformer 层数的影响,取值范围为 {1,2,3}。如图 6(c)所示,两层 Transformer 效果最佳,因为层数增加会增加模型复杂度,导致容易过拟合,层数太少则不能完全捕捉轨迹的时空特征。

(4)推理阶段采样策略的温度系数对轨迹生成的

影响,取值范围为 {0.2,0.4,0.6,0.8,1.0,1.2,1.4}。温度系数控制采样过程的随机性,低值时模型更倾向于选择高概率输出,行为更具确定性;而较高值则增强生成结果的多样性。实验结果如图 6(d)所示,当温度系数为 0.8 时,模型性能最优,生成的轨迹在合理性和多样性之间达到良好平衡。当温度低于 0.8 时,性能未提升,因为近似贪婪的采样策略可能会陷入局部最优,破坏全局合理性。而当温度高于 0.8 时生成质量下降,过高的随机性可能会导致轨迹偏离真实空间分布,引入不合理的路径。

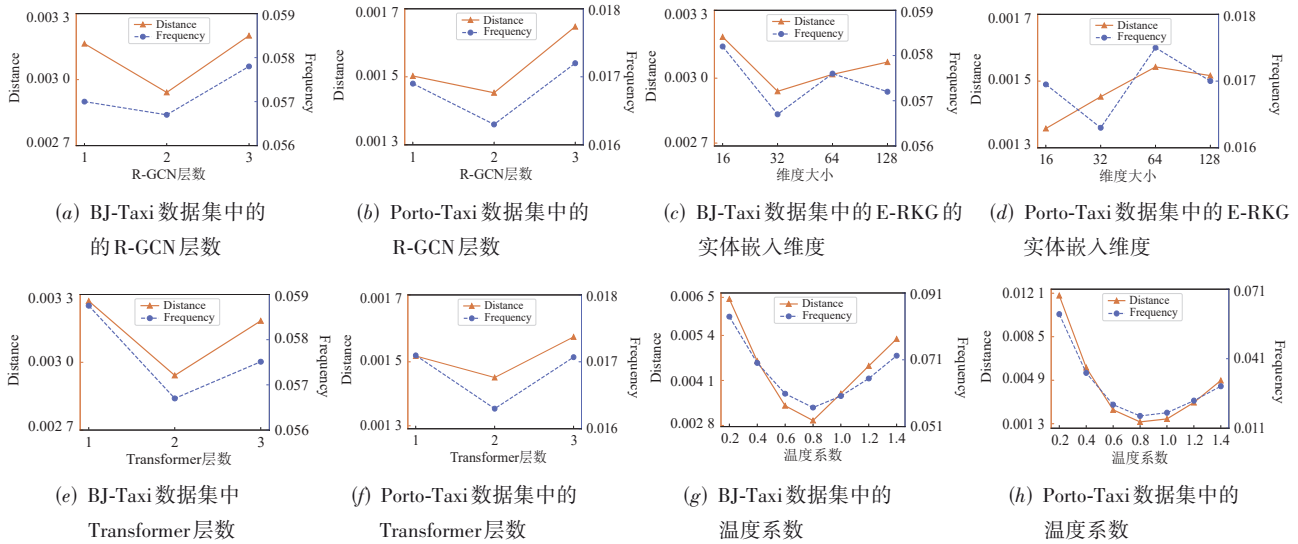


图 6 超参数实验

5.8 计算成本实验

从参数量、训练时间和推理时间角度来分析模型的计算成本。如表 7 所示,KG-TrajGen 的计算成本相对适中,展现出良好的训练效率和推理速度平衡。在训练阶段,KG-TrajGen 训练速度显著快于 UPGLD 和 TS-TrajGen。同时,相较于参数量相近的 STEGA,KG-TrajGen 速度有较大提升,因为使用了轻量 R-GCN,而 STEGA 则引入了复杂的门控机制和图注意力算法,带来更高的计算开销。在推理阶段,KG-TrajGen 表现也较为突出,尽管 LSTM-TrajGAN 和 ControlTraj 的训练时间较短,但代价是生成轨迹质量差,并且推理阶段需要

额外的地图匹配操作,导致推理延迟显著增加,严重制约实际部署效率。相比之下,KG-TrajGen 无需地图匹配,实现了高效且高质量的端到端轨迹生成。

此外,由于 KG-TrajGen 以道路为核心实体构建知识图谱,因此路网规模越大,模型复杂度越高。由表 2 可知,北京路网规模显著大于 Porto(路段数约为 3 倍),导致 KG-TrajGen 在 BJ-Taxi 上的模型参数量更多,训练时间也相应增加。但如表 3 所示,KG-TrajGen 在 BJ-Taxi 上的生成性能仍全面优于所有基线方法,且推理时间保持在较低水平(~2.4 min),这表明 KG-TrajGen 在更大规模、更高复杂度的城市场景中仍展现出优异的性能与良好的可扩展性,具备实际部署潜力。

表 7 计算成本实验

模型	参数量/Million		训练时间/h		推理时间/min	
	BJ-Taxi	Porto-Taxi	BJ-Taxi	Porto-Taxi	BJ-Taxi	Porto-Taxi
LSTM-TrajGAN	0.1	0.1	~0.3	~0.2	~16.6	~5.1
TS-TrajGen	33.6	12.2	~34.3	~42.5	~23.0	~15.3
UPGLD	59.0	59.0	~31.8	~28.0	~100.3	~151.7
ControlTraj	8.8	8.8	~6.6	~5.6	~18.6	~6.9
STEGA	21.7	7.6	~42.2	~15.3	~1.0	~1.6
KG-TrajGen(Ours)	22.6	8.6	~17.4	~7.7	~2.4	~3.3

6 结论

本文提出一种 KG-TrajGen, 该模型采用 RKG 学习路段表示, 能够捕获局部和全局空间依赖关系; 并利用 E-RKG 捕获道路与周围城市环境的交互作用, 将城市环境信息有效地融入轨迹生成过程. 在两个真实轨迹数据集上的对比实验表明: KG-TrajGen 在统计特征误差、频繁模式特征误差和轨迹误差方面显著优于现有的最先进的基线方法. 此外, 消融实验、少样本实验和下游任务实验进一步验证了 KG-TrajGen 的有效性和实用性. 为了平衡模型的稳定性和性能, KG-TrajGen 在时空嵌入层之后融入 E-RKG. 未来工作将探索更精细的图结构设计或噪声抑制机制, 以更早地引入 E-RKG, 例如时空嵌入层引入, 这有望在降低模块冗余的同时进一步提升生成轨迹的质量.

参考文献

- [1] JIANG W J, ZHAO W X, WANG J Y, et al. Continuous trajectory generation based on two-stage GAN[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Washington: AAAI, 2023, 37(4): 4374-4382.
- [2] FENG J, YANG Z Y, XU F L, et al. Learning to simulate human mobility[C]//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM, 2020: 3426-3433.
- [3] DU Y T, HU Y J, ZHANG Z K, et al. LDPTrace: Locally differentially private trajectory synthesis[J]. Proceedings of the VLDB Endowment, 2023, 16(8): 1897-1909.
- [4] 曾卓, 汪成亮, 马飞. 基于差分隐私的活动模式保护与时空轨迹发布方法[J]. 电子学报, 2023, 51(3): 552-563.
ZENG Z, WANG C L, MA F. Differentially private activity pattern and spatial-temporal trajectory publication[J]. Acta Electronica Sinica, 2023, 51(3): 552-563. (in Chinese)
- [5] 蒋伟进, 王海娟, 周为, 等. 基于自适应连续时间的群智感知轨迹隐私保护方案[J]. 电子学报, 2023, 51(10): 2894-2901.
JIANG W J, WANG H J, ZHOU W, et al. Track privacy protection scheme based on adaptive continuous time in crowdsensing[J]. Acta Electronica Sinica, 2023, 51(10): 2894-2901. (in Chinese)
- [6] SIMINI F, BARLACCHI G, LUCA M, et al. A Deep Gravity model for mobility flows generation[J]. Nature Communications, 2021, 12: 6576.
- [7] JIANG S, YANG Y X, GUPTA S, et al. The TimeGeo modeling framework for urban motility without travel surveys[J]. PNAS, 2016, 113(37): E5370-E5378.
- [8] CAO C, LI M. Generating mobility trajectories with retained data utility[C]//Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining. New York: ACM, 2021: 2610-2620.
- [9] WANG X R, LIU X Y, LU Z T, et al. Large scale GPS trajectory generation using map based on two stage GAN[J]. Journal of Data Science, 2021, 19(1): 126-141.
- [10] ZHU Q Y, CHEN Y Z, WANG H, et al. A knowledge-enhanced framework for imitative transportation trajectory generation[C]//2022 IEEE International Conference on Data Mining. Piscataway: IEEE, 2023: 823-832.
- [11] WANG Y, CAO J, HUANG W J, et al. Spatiotemporal gated traffic trajectory simulation with semantic-aware graph learning[J]. Information Fusion, 2024, 108: 102404.
- [12] NING Y, LIU H, WANG H, et al. UUKG: Unified urban knowledge graph dataset for urban spatiotemporal prediction[C]//Advances in Neural Information Processing Systems 36. San Diego: NeurIPS, 2023: 62442-62456.
- [13] CAO Z S, XU Q Q, YANG Z Y, et al. Geometry interaction knowledge graph embeddings[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2022, 36(5): 5521-5529.
- [14] LIN Y, WAN H Y, GUO S N, et al. Pre-training context and time aware location embeddings from spatial-temporal trajectories for user next location prediction[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(5): 4241-4248.
- [15] WANG H D, YU Q H, LIU Y, et al. Spatio-temporal urban knowledge graph enabled mobility prediction[J]. Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2021, 5(4): 1-24.
- [16] CHEN L, YING Y K, LYU D D, et al. A multi-task embedding based personalized POI recommendation method[J]. CCF Transactions on Pervasive Computing and Interaction, 2021, 3(3): 253-269.
- [17] ZHU Y S, YE Y C, ZHANG S Y, et al. DiffTraj: Generating GPS trajectory with diffusion probabilistic model[C]//The 37th Conference on Neural Information Processing Systems. New Orleans: NeurIPS Foundation, 2023: 65168-65188.
- [18] HAYDARIA, CHEN D J, LAI Z F, et al. MobilityGPT: Enhanced human mobility modeling with a GPT model[EB/OL]. (2024-05-23)[2025-10-06]. <https://arxiv.org/abs/2402.03264>.
- [19] MAGLARAS L A, KATSAROS D. Social clustering of vehicles based on semi-Markov processes[J]. IEEE Transactions on Vehicular Technology, 2016, 65(1): 318-332.
- [20] YU L T, ZHANG W N, WANG J, et al. SeqGAN:

Sequence generative adversarial nets with policy gradient[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2017, 31(1): 2852-2858.

- [21] FARHA Y ABU, RICHARD A, GALL J. When will you do what? - Anticipating temporal occurrences of activities[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 5343-5352.
- [22] HUANG D, SONG X, FAN Z P, et al. A variational autoencoder based generative model of urban human mobility[C]//2019 IEEE Conference on Multimedia Information Processing and Retrieval. Piscataway: IEEE, 2019: 425-430.
- [23] RAO J, GAO S, KANG Y, et al. LSTM-TrajGAN: A deep learning approach to trajectory privacy protection[EB/OL]. (2020-06-14)[2025-10-06]. <https://arxiv.org/abs/2006.10521>.
- [24] ZHANG L M, ZHAO L, PFOSE D. Factorized deep generative models for end-to-end trajectory generation with spatiotemporal validity constraints[C]//Proceedings of the 30th International Conference on Advances in Geographic Information Systems. New York: ACM, 2022: 1-12.
- [25] ZHU Y S, YU J J, ZHAO X Y, et al. ControlTraj: Controllable trajectory generation with topology-constrained diffusion model[C]//Proceedings of the 30th ACM SIGKDD


Conference on Knowledge Discovery and Data Mining. New York: ACM, 2024: 4676-4687.

- [26] SONG Y W, DING J T, YUAN J, et al. Controllable human trajectory generation using profile-guided latent diffusion[J]. ACM Transactions on Knowledge Discovery from Data, 2024, 19(1): 1-25.
- [27] SHAO C Y, XU F L, FAN B B, et al. Chain-of-planned-behaviour workflow elicits few-shot mobility generation in LLMs[EB/OL]. (2024-06-05)[2025-10-16]. <https://arxiv.org/abs/2402.09836>.
- [28] CHUNG J, GULCEHRE C, CHO K, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling[EB/OL]. (2014-12-11)[2025-10-16]. <https://arXiv.org/abs/1412.3555>.
- [29] ZIAT A, DELASALLES E, DENOYER L, et al. Spatio-temporal neural networks for space-time series forecasting and relations discovery[C]//2017 IEEE International Conference on Data Mining. Piscataway: IEEE, 2017: 705-714.
- [30] BAI L, YAO L N, LI C, et al. Adaptive graph convolutional recurrent network for traffic forecasting[C]//Proceedings of the 34th International Conference on Neural Information Processing Systems. New York: ACM, 2020: 17804-17815.

作者简介



李 康 男,2001年3月出生于安徽省宿州市.现为浙江师范大学计算机科学与技术学院硕士研究生.主要研究方向为时空数据挖掘.
E-mail: lk2023@zjnu.edu.cn



邱 晨 男,1994年8月出生于浙江省绍兴市.现为浙江师范大学计算机科学与技术学院讲师.主要研究方向为流体重建.
E-mail: qiusheng@zjnu.cn



于 娟 女,1983年9月出生于湖南省张家界市.现为浙江师范大学计算机科学与技术学院副教授、硕士生导师.主要研究方向为时空数据挖掘、数据隐私保护.
E-mail: yujuan@zjnu.edu.cn



杨 琼 女,1982年5月出生于湖南省吉首市.现为浙江工业职业技术学院信息与设计学院副教授.主要研究方向为时空数据挖掘、隐私保护.
E-mail: yangqiong525@hdu.edu.cn



韩建民 男,1969年7月出生于辽宁省大连市.现为浙江师范大学计算机科学与技术学院教授,博士生导师.主要研究方向为数据隐私保护.
Email: hanjm@zjnu.cn