

# 融合位置先验的生成对抗模仿学习轨迹生成<sup>①</sup>



王 威, 于 娟, 邱 晟, 姚 鑫, 阮方昱

(浙江师范大学 计算机科学与技术学院, 金华 321004)

通信作者: 于 娟, E-mail: [yujuan@zjnu.edu.cn](mailto:yujuan@zjnu.edu.cn)

**摘 要:** 现有基于生成对抗模仿学习 (GAIL) 的轨迹生成方法多采用马尔可夫决策过程 (MDP) 建模人类移动规律, 在训练数据有限的情况下, 这些工作难以学习到动作选择与位置间的潜在关系, 并且计算状态转移函数时也没有考虑到位置间的距离约束, 生成的轨迹质量有待提升. 为此, 本文提出了一种基于生成对抗模仿学习的轨迹生成方法, 该方法首先将位置相关的动作分布先验知识融入到生成器中, 帮助模型理解在特定位置上动作的变化模式, 指导模型更好地建模符合真实场景的策略函数. 此外, 将距离约束引入到状态转移函数中, 确保生成轨迹的合理性. 在两个真实数据集上进行了实验, 提出的方法在 Rank 指标上达到了 0.0268, 与最好的基线方法相比提高了 39%. 此外, 在下一个位置预测任务中, 预测的准确率比最好的基线高了 6%.

**关键词:** 生成对抗模仿学习; 轨迹生成; 马尔可夫决策过程; 位置先验知识; 状态转移函数

引用格式: 王威, 于娟, 邱晟, 姚鑫, 阮方昱. 融合位置先验的生成对抗模仿学习轨迹生成. 计算机系统应用. <http://www.c-s-a.org.cn/1003-3254/9866.html>

## Generative Adversarial Imitation Learning Trajectory Generation Incorporating Location Priors

WANG Wei, YU Juan, QIU Sheng, YAO Xin, RUAN Fang-Yu

(School of Computer Science and Technology, Zhejiang Normal University, Jinhua 321004, China)

**Abstract:** Existing trajectory generation methods based on generative adversarial imitation learning (GAIL) mostly use the Markov decision process (MDP) to model human movement patterns. With limited training data, it is difficult to learn the potential relationship between action selection and locations, and the distance constraints between locations are not taken into account in the calculation of the state transition function. Therefore, the quality of the generated trajectories needs to be improved. For this reason, this study proposes a trajectory generation method based on generative adversarial imitation learning. The method first incorporates priori knowledge of the location-related action distribution into the generator to help the model understand the change patterns of the actions at a specific location, guiding it to better model the policy function that conforms to the real scenario. In addition, distance constraints are introduced into the state transition function to ensure the rationality of the generated trajectories. Experiments conducted on two real datasets show that the proposed method achieves a Rank index of 0.0268, which is 39 % better than that of the best baseline method. In addition, the accuracy of the prediction in the next position prediction task is 6 % higher than that of the best baseline.

**Key words:** generative adversarial imitation learning (GAIL); trajectory generation; Markov decision process; priori knowledge of location; state transition function

<sup>①</sup> 基金项目: 国家自然科学基金 (61702148, 61672648)

收稿时间: 2024-11-19; 修改时间: 2024-12-09; 采用时间: 2024-12-24; csa 在线出版时间: 2025-03-24

## 1 引言

移动轨迹数据在城市规划、智慧交通以及流行病管控等方面发挥着具有重要作用<sup>[1-4]</sup>。然而,人类移动轨迹数据的共享和发布会威胁个人隐私,这极大地限制了其应用价值<sup>[5,6]</sup>。为了促进轨迹数据的共享,研究者们采用合成轨迹替代真实轨迹,以缓解轨迹发布中的用户隐私问题。因此,如何生成高质量的合成轨迹具有重要的意义。

近年,生成对抗模仿学习(GAIL)的快速发展为生成高质量的合成轨迹提供了新的思路。基于GAIL的研究初期,Wei等人<sup>[7]</sup>将GAIL与插值法结合,首先用插值法将稀疏轨迹插值成稠密轨迹,再利用对抗的思想生成真实的车辆轨迹。但是该模型使用简单的MDP建模,即假设当前位置由前一时刻位置决定。为了克服简单MDP模型的不足,Choi等人<sup>[8]</sup>采用GAIL的模型,利用部分可观测的马尔可夫决策过程(POMDP)建模车辆轨迹。为了进一步提高合成轨迹的质量,Wang等人<sup>[9]</sup>利用GAIL模拟人的决策过程,基于广泛采用的EPR模型定义了动作空间和状态转移概率。Wu等人<sup>[10]</sup>基于GAIL生成人类轨迹,并结合移动行为的语义对决策过程进行显式建模。此类方法将移动轨迹建模为马尔可夫决策过程(MDP),并采用GAIL方法建模模型中未知的策略函数和奖励函数。但是,基于GAIL的方法存在以下不足。首先,未充分利用人类移动的规律性,有限的专家数据难以让模型自动学习到动作选择与位置属性间的潜在关系<sup>[11]</sup>。其次,未充分考虑人类移动的物理约束条件,状态转移概率计算仅依赖位置的历史访问频率,忽略了运动速度约束,从而产生不合理的轨迹数据<sup>[12]</sup>。

为此,本文提出了一种基于GAIL的轨迹生成方法LAPGAIL(location action prior generative adversarial imitation learning),主要工作如下。

(1) 提出了一种基于GAIL的轨迹生成方法LAPGAIL。LAPGAIL通过引入LocAct模块融合位置相关的动作分布,弥补现有基于GAIL方法难以自动学习动作选择与位置属性间的潜在关系的不足,进而提升合成轨迹质量。

(2) 设计了一种考虑距离约束的状态转移函数,在状态转移概率的计算过程中引入距离约束,以避免生成不符合物理运动规律的轨迹。

(3) 在两个真实轨迹数据集上进行了对比实验,实验结果表明所提出的方法生成的合成轨迹在宏观相似性,微观相似性等指标上优于对比的基线模型。

## 2 基本概念

定义1(移动轨迹)。用户 $u$ 的一条移动轨迹由一组时空点 $\mathcal{T}=\{x_1, x_2, \dots, x_3\}$ 组成,其中每个时空点 $x_i$ 可以表示为 $(l_i, t_i)$ , $t_i$ 表示时间戳, $l_i$ 表示 $t_i$ 时刻用户所在的位置。

定义2(马尔可夫决策过程)。MDP是在环境中模拟智能体的随机策略与回报的数学模型,且环境的状态具有马尔可夫性质。可形式化描述为一个五元组 $\langle \mathcal{S}, \mathcal{A}, \pi, P, R \rangle$ ,其中 $\mathcal{S}$ 表示状态空间, $\mathcal{A}$ 表示动作空间, $\pi$ 表示随机策略函数, $P$ 表示状态转移函数, $R$ 表示即时奖励函数。

将移动轨迹建模为MDP,其各个要素的具体定义如下。

(1) 状态空间 $\Sigma$ 由若干个离散的状态 $s$ 构成,每个状态包含3个元素 $s=(l, t, c)$ ,其中 $l$ 表示用户当前的位置, $t$ 表示时间戳, $c=(h, \tau, m, T^c)$ 表示上下文信息。上下文信息中:

$h$ 表示家的位置:用户家的位置会影响整体轨迹的规划,作为一个重要的上下文信息确保生成的轨迹与用户的真实行为相符。

$\tau$ 表示停留时间:用户在位置 $l$ 的停留时间步数。

$m$ 表示历史访问的不同位置的数量:随着用户当前访问过的不同位置数量的增加,用户探索新位置的倾向随之下降<sup>[13]</sup>。

$T^c$ 表示过去一天的子轨迹:以上特征主要表征了用户当前的移动状态。因此,将过去一天内的用户子轨迹作为另一个特征表征历史状态,表示为 $T^c=\{(l_j, t_j) \mid 0 \leq j < 48\}$ 。

(2) 动作空间定义为 $\mathcal{A}=\{\text{停留, 返回家的位置, 返回, 探索}\}$ ,包含4种可能动作,其中:

停留:表示用户将在下一个时间片停留在当前位置。

返回家的位置:表示用户将在下一个时间片返回家的位置。

返回:用户在下一个时间片选择迁移到它以前访问过的位置,但不是用户家的位置。

探索:表示用户将探索新的之前未访问过的位置。

(3) 随机策略函数 $\pi(a_i \mid s_i)$ 是在状态 $s_i$ 下采取动

作  $a_i$  的条件概率, 可记为:

$$\pi(a_i | s_i) = P(a_i | l_i, t_i, \tau_i, m_i, h) \quad (1)$$

(4) 状态转移函数  $P: \mathcal{S} \times \mathcal{A} \times \mathcal{S} \rightarrow \mathbb{R}$ , 记为  $P(s_{i+1} | s_i, a_i)$ , 表示给定当前状态  $s_i$  和动作  $a_i$ , 下一个状态  $s_{i+1}$  出现的概率. 描述了基于当前状态和动作生成下一个状态的概率分布.

(5) 即时奖励函数  $R: \mathcal{S} \times \mathcal{A} \rightarrow R$ , 记为  $R(s_i, a_i)$ , 表示用户在状态  $s_i$  下执行动作  $a_i$  所获得的即时奖励.

### 3 LAPGAIL 网络模型

通过将移动轨迹建模为 MDP, 轨迹生成即为用该随机过程进行轨迹采样. 由于在真实世界环境中人类智能体的移动策略和奖励函数都是未知的, 所以人类移动轨迹的生成问题即可转换为求解马尔可夫随机过程中未知策略函数与奖励函数的问题. 可形式化描述

为: 在 MDP 模型中, 轨迹生成可以被视为是智能体在环境中按照某一策略  $\pi$  进行决策和移动. 即, 智能体根据当前状态  $s_i$  选择下一个动作  $a_i$ , 接着依据状态转移函数  $P(s_{i+1} | s_i, a_i)$  进入下一个状态  $s_{i+1}$ , 并获得相应的奖励  $R(s_i, a_i)$ . 采用 GAIL 求解未知的策略函数与奖励函数.

为了更好地捕获移动特征、更合理地建模移动轨迹, 基于 GAIL 模型提出了新的模型 LAPGAIL, 它从专家轨迹数据中建模策略函数和奖励函数. LAPGAIL 由生成器和鉴别器组成. 其中, 生成器 G 由两部分组成: ActNet 和 LocAct. ActNet 学习状态到动作的映射模式; LocAct 可以了解在特定位置上动作的分布特性, 解决有限的专家数据难以让模型自动学习到动作选择与位置属性间的潜在关联的问题. 鉴别器 D 评估生成行为与专家行为的相似度, 从而指导生成器学习, 如图 1 所示.

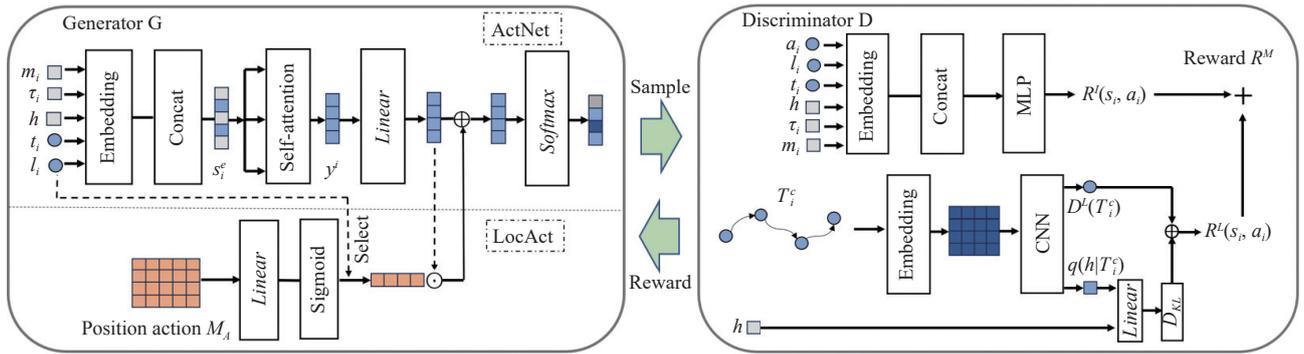


图 1 LAPGAIL 网络模型

#### 3.1 融合位置相关动作先验分布的生成器

如图 1 所示, 生成器由两部分组成: ActNet 基于当前状态生成初步的动作; LocAct 通过分析位置动作分布, 帮助 ActNet 做出更为合理的动作决策.

##### 3.1.1 ActNet 模块

采用基于自注意力网络的方法来捕获移动轨迹中的复杂相关性和规律性. 在给定当前状态  $s_i$  的情况下, 生成器网络建模决策策略  $\pi(a_i | s_i)$ . 然后, 根据决策策略  $\pi(a_i | s_i)$ , 网络随机选择一个动作, 决定下一个生成位置.

##### 3.1.2 LocAct 模块

当用户生成移动轨迹时, 位置属性对动作选择至关重要<sup>[11]</sup>. 虽然动作选择与位置属性间的潜在关联可以使用 ActNet 通过鉴别器的反馈从移动数据中学习, 但实验证明, 这种纯粹的学习方式很难学习到它们之

间的潜在关联. 因此, 设计了一个 LocAct 模块, 整合位置动作先验知识, 并帮助 ActNet 做出更为合理的动作决策. 具体来说, 在对城市空间离散划分的基础上, 每个位置都有一个动作先验分布, 整合所有  $N$  个位置上的动作先验分布, 构建一个  $4 \times N$  的位置动作关系矩阵  $M_A$ . 位置动作关系矩阵  $M_A$  聚合了真实数据中所有位置选择的动作. 利用当前位置从矩阵中选择有用的信息, 帮助 ActNet 做出更为合理的动作决策. 首先, 使用最新生成的位置  $l_{i-1}$  从位置动作关系矩阵  $M_A$  中提取与当前位置  $l_{i-1}$  相应的关系向量  $r_a$ . 然后, 通过逐元素相乘, 将 ActNet 生成的动作特征向量  $\hat{a}_i$  与关系向量  $r_a$  融合. 最后, 做残差连接生成最终结果  $a_i$ , 公式如下:

$$r_a = \sigma(\text{Linear}(M_A)) \times l_{i-1} \quad (2)$$

$$a_i = \text{Softmax}(\hat{a}_i + \hat{a}_i \odot r_a) \quad (3)$$

其中,  $\sigma$  是 ReLU 函数,  $\odot$  是逐元素乘法.

LocAct 模块在模型中起着关键作用. 首先,  $r_a$  提供了与当前位置  $l_{i-1}$  相关的动作先验知识, 使模型能够考虑当前位置的动作分布特征, 可以帮助模型理解特定位置上更可能采取哪些动作. 其次, 通过与当前动作特征向量  $\hat{a}_i$  逐元素相乘, 可以有效地调整和增强动作的特征表示, 使其更符合真实情况. 然后, 结合位置相关的信息后, 模型能够生成更加准确的下一个动作概率分布  $a_i$ . 这种改进有助于捕捉复杂的移动模式和行为规律, 提高整体的预测性能. 最后, 通过整合先验知识, 可以帮助模型减少由数据噪声或不确定性带来的误导, 从而使学习过程更加稳健.

### 3.2 考虑空间约束的状态转移函数

状态转移函数表示状态转移概率, 即  $P(s_{i+1} | s_i, a_i)$  表示给定当前状态  $s_i$  和动作  $a_i$ , 下一个状态  $s_{i+1}$  出现的概率. 下一个状态由  $l_{i+1}$ 、 $t_{i+1}$  和  $c_{i+1}$  组成. 其中,  $t_{i+1}$  的迁移是确定的, 即  $t_{i+1} = t_i + 1$ .  $l_{i+1}$  和  $c_{i+1}$  与动作选择有关, 因此:

(1) 当动作  $a_i$  是停留时, 下一个位置为  $l_i$ . 下一个时间片的上下文信息中只有停留时间加 1, 其余不变.

(2) 当动作  $a_i$  是返回家的位置时, 下一个位置为用户家的位置. 下一个时间片的上下文信息中停留时间变为 1, 其余不变.

(3) 当动作  $a_i$  是返回时, 下一个时间片的上下文信息中停留时间变为 1, 其余不变. 选择下一个位置时需要满足一个距离阈值  $thr_{dis}$ , 将以以下概率分布选择特定位置:

$$f_R(l_i, l_{i+1}, distance) = \begin{cases} k_{i+1}/k_{all}, & \text{if } distance(l_i, l_{i+1}) \geq thr_{dis} \\ f_{i+1}/k_{all}, & \text{others} \end{cases} \quad (4)$$

其中,  $k_{i+1}$  表示用户在第  $l_{i+1}$  位置的历史访问次数,  $f_{i+1}$  表示去除超过阈值  $thr_{dis}$  的位置的其他之前访问过的位置的历史访问次数,  $k_{all}$  表示用户在所有位置的总访问次数.  $distance(l_i, l_{i+1})$  表示位置  $l_i$  和位置  $l_{i+1}$  之间的距离.

(4) 当动作  $a_i$  是探索时, 下一个时间片的上下文信息中停留时间变为 1, 历史访问的不同位置的数量加 1, 其余不变. 选择下一个位置时, 根据到当前位置  $l_i$  的距离, 对每个候选目的地  $l_{i+1}$  有一个排名  $k(l_i, l_{i+1})$ . 例如: 离当前位置  $l_i$  最近的位置  $l_1$  有  $k(l_i, l_1)=1$ , 第 2 个最近的位置有  $k(l_i, l_2)=2$ , 以此类推. 然后, 有:

$$f_E(l_i, l_{i+1}) \propto k(l_i, l_{i+1})^{-\alpha} \quad (5)$$

其中,  $\alpha$  是对距离的敏感度.  $\alpha$  越小意味着人们对旅行距离的敏感度越低, 旅行距离就会越长.

### 3.3 鉴别器

GAIL 使用鉴别器网络近似奖励函数对状态-动作对进行评分. 然而, 人类的移动特征是复杂多样的, 简单的建模奖励函数无法捕获复杂的信息, 并且还会面临复合误差和协变量偏移<sup>[14,15]</sup>. 为此, 将整个复杂的时空移动信息分为两种不同的类型——即时信息和全局特征. 因此, 鉴别器网络有两个优化目标, 即时奖励函数  $R^I$  和长期奖励函数  $R^L$ , 如图 1 所示. 对于即时奖励函数  $R^I$ , 以来自生成器网络的采样动作  $a$  和状态  $s$  (不包含过去一天的子轨迹  $T^c$ ) 作为输入, 经过 MLP 层得到动作  $a$  的即时奖励. 对于长期奖励函数  $R^L$ , 计算过去一天的子轨迹  $T^c$  和家的位置的互信息, 得到长期信息的判别结果. 这样就可以从多个角度得到奖励函数  $R^M$ :

$$R^M = R^I + \gamma R^L \quad (6)$$

其中,  $\gamma > 0$  是平衡即时奖励和长期奖励影响的参数.

### 3.4 模型训练

由于移动轨迹序列中复杂的迁移和各种噪声, 很难从原始数据集中高效地学习有用的知识. 通常分两阶段训练模型, 第 1 阶段分别单独预训练生成器和鉴别器, 第 2 阶段为生成器和鉴别器的 GAIL 对抗训练.

预训练. 为了提高整个模型的性能并加速训练过程, 参照现有 MoveSim<sup>[16]</sup> 的预训练机制, 首先对模型的生成器和鉴别器进行预训练. 为此, 设计移动预测任务预训练生成器, 设计二分类任务训练鉴别器.

GAIL 对抗训练. 预训练得到的策略函数不能保证总的奖励最优, 需要基于 GAIL 损失进一步训练. 具体来说, 通过 PPO 算法更新策略函数  $\pi$ , 生成器的损失函数如下:

$$L_G = \mathbb{E}_\pi [\min(r_t \cdot A_t, \text{clip}(r_t, 1 - \epsilon, 1 + \epsilon) \cdot A_t)] \quad (7)$$

其中,  $r_t = \pi(a | s) / \pi_{old}(a | s)$  控制新策略更新幅度,  $A_t$  是优势函数,  $\epsilon$  是截断参数.

至于鉴别器, 首先根据当前策略进行轨迹采样, 然后基于标准 GAN 损失进行训练, 损失函数如下:

$$L_D = \mathbb{E}_\pi [\log D(s, a)] + \mathbb{E}_{\pi_E} [\log (1 - D(s, a))] \quad (8)$$

其中,  $\mathbb{E}_\pi$  是策略  $\pi$  生成合成轨迹的期望.  $\pi_E$  表示专家轨迹的策略.

目标函数表示如下:

$$\min_{\pi} \max_{D^I, D^L} \mathbb{E}_{\pi} [R^M(s, a)] + \mathbb{E}_{\pi_E} [\log(1 - D^I(s, a))] + \lambda \mathbb{E}_{\pi_E}^L [\log(1 - D^L(s, a))] - H(\pi) \quad (9)$$

其中,  $H(\pi)$  是策略  $\pi$  的因果熵.

## 4 实验分析

本文使用 2 个真实的移动轨迹数据集验证提出模型的性能. 2 个数据集分别是 GeoLife、T-drive, 以下是对 2 个数据集的描述.

(1) GeoLife<sup>[17]</sup>: 数据集包含 182 名用户在 5 年多的时间里 (2007 年 4 月–2012 年 8 月) 通过不同的 GPS 记录仪和 GPS 手机收集的轨迹. 它包含 17 621 条轨迹, 总距离为 1 251 654 公里. 其中每条轨迹由一系列采样点构成, 每个采样点包含时间戳、纬度和经度信息.

(2) T-drive<sup>[18]</sup>: 数据集包含 2008 年 2 月 2 日–2 月 8 日北京 10 357 辆出租车的 GPS 轨迹. 它总共包含 1 500 万个 GPS 点, 总距离为 900 万公里. 其中每条轨迹定义为一系列的点, 包含时间戳、维度和经度信息.

### 4.1 基线模型

将 LAPGAIL 与 4 个基线模型进行比较, 包括以下模型.

(1) SeqGAN<sup>[19]</sup>: 它通过将强化学习引入到 GAN 中, 解决离散序列生成问题. 将生成过程视为一个序列决策过程, 其中生成器负责生成序列数据, 而鉴别器则负责评估生成数据的真实性.

(2) MoveSim<sup>[16]</sup>: 它是基于 GAN 合成人类轨迹的方法, 在 SeqGAN 模型中引入了先验知识和物理规律.

(3) PateGail<sup>[9]</sup>: 利用 GAIL 模拟人的决策过程, 基于广泛采用的 EPR 模型定义了动作空间和状态转移概率, 并且采用一种新颖的用户鉴别器奖励汇总机制.

(4) GeoGail<sup>[10]</sup>: 该模型是基于模仿学习的方法生成人类轨迹, 并结合移动行为的语义对决策过程进行显式建模.

### 4.2 度量指标

与以往的工作类似, 采用 10 个指标分别从宏观相似性度量、微观相似性度量和可解释性度量方面评估生成数据的质量.

#### 4.2.1 宏观相似性度量指标

采用 JS 散度度量合成轨迹和真实轨迹之间重要移动模式分布的相似度. JS 散度值越低, 生成的结果越

好. 指标定义如下.

(1) Distance: 不同用户在固定时间间隔内的累计行驶距离.

(2) Radius: 表示用户日常运动的空间范围.

(3) DailyLoc: 每个用户每天的访问位置数量.

(4) Rank: 每个用户前 100 个位置的访问频率.

(5) Exploration: 访问新位置的概率, 是访问位置数量的函数.

#### 4.2.2 微观相似性度量指标

(1) 豪斯多夫距离 (Hausdorff distance): 度量两个点集之间最大不匹配程度. Hausdorff distance 的计算公式如下所示:

$$H(A, B) = \max(h(A, B), h(B, A)) \quad (10)$$

其中,  $h(A, B) = \max_{a \in A} \left\{ \min_{b \in B} \|a - b\| \right\}$ ,  $\|\cdot\|$  是点集  $A$  和  $B$  之间的距离范式. Hausdorff distance 值越小表示数据效用越高.

(2) 轨迹集的编辑距离 (edit distance): 轨迹集中所有单个轨迹编辑距离的平均值, 见式 (11). 单个轨迹编辑距离是指将一个序列变换为另一个序列所需的最小操作次数.

$$ED = \frac{1}{N} \sum_{i=1}^N \min \left( \frac{\text{edit}(\widehat{T}, T)}{|T_i|}, 1 \right) \quad (11)$$

其中,  $N$  是真实轨迹数据集中的轨迹数量,  $\widehat{T}$  是生成的轨迹,  $T$  是真实轨迹,  $|T_i|$  是轨迹长度.  $ED$  值越小表示合成轨迹与真实轨迹越相似.

#### 4.2.3 可解释性度量指标

(1) Weekly home-based tour number  $N_w$ : 用户一定时间内从家出发进行活动的次数, 反映了用户的活动频率, 计算公式如下:

$$N_w = \frac{e}{w \times m} \quad (12)$$

其中,  $e$  是在家位置到其他非家位置的迁移次数;  $w$  是用户轨迹记录的持续时间;  $m$  是每天划分的时间片的数量.

(2) Burst rate  $\beta_1$ : 用户进行一系列不同活动的频率, 有助于理解个体出行行为的多样性和变化性, 计算公式如下:

$$\beta_1 = \frac{e_1}{w \times m \times g} \quad (13)$$

其中,  $e_1$  是在非家位置到其他非家位置的迁移次数;

$g$  是每天的位置迁移次数。

(3) Dwell rate  $\beta_2$ : 用户一定时间内在特定地点停留的时间, 反映了用户在特定地点停留的倾向, 计算公式如下:

$$\beta_2 = \frac{e_2}{w \times m \times g} \quad (14)$$

其中,  $e_2$  是在非家位置保持不变的次数。

### 4.3 实验环境与参数

用 Python 实现了所有方法, 所有实验都在一台装有 1 个 NVIDIA GeForce RTX 3090 的 Linux 服务器上运行. 预训练过程的学习率设置为 0.0003, GAIL 训练过程的 0.00003. LAPGAIL 模型使用的超参数如表 1 所示.

表 1 LAPGAIL 模型训练超参数

超参数	值
批量大小	64
位置嵌入维度	64
时间嵌入维度	8
隐向量维度	64
学习率	0.0003/0.00003
式(6)中的 $\gamma$	0.1

#### ● 距离敏感度 $\alpha$ 选择

在选择探索动作时, 由概率  $f_E(l_i, l_{i+1}) \propto k(l_i, l_{i+1})^{-\alpha}$  确定探索的位置, 该概率与  $k(l_i, l_{i+1})$  的负  $\alpha$  次方成正比.  $\alpha$  是对距离的敏感度,  $\alpha$  越小, 意味着人们对旅行距离的敏感度越低, 旅行距离就会越长. 当个体决定探索某个目的地时, 用经验概率  $f_E(l_i, l_{i+1})$  表示选择目的地的概率. 对于每个数据集, 根据目的地与起始点的距离对每个可能的目的地排名, 选取距离最近的前  $k$  个位置作为潜在的出行目的地, 并绘制了相应的经验概率分布图, 其中横坐标表示前  $k$  个位置的排名, 如图 2、图 3 所示.

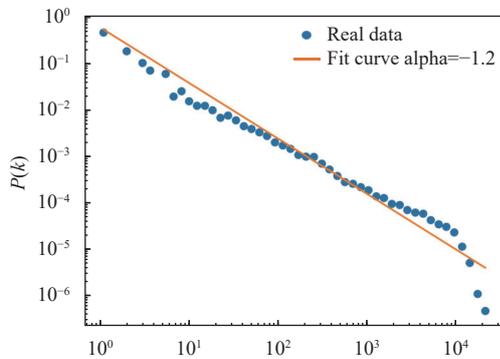


图 2 GeoLife 数据集经验概率

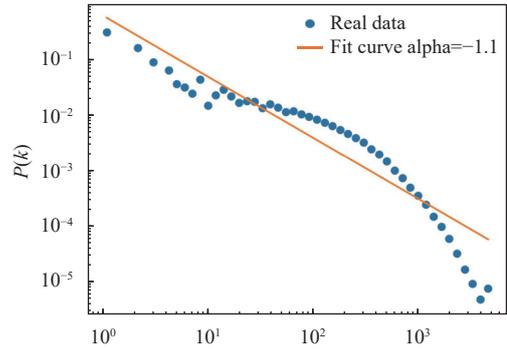


图 3 T-drive 数据集经验概率

#### ● 损失收敛曲线

LAPGAIL 模型的生成器损失和鉴别器损失如图 4、图 5 所示. 训练初期, 生成器生成的样本质量较差, 损失波动较大. 而鉴别器最初可以轻松区分真假轨迹, 但随着生成器的优化, 鉴别器越难以区分两者, 损失值逐渐降低. 随着模型进行对抗训练, 生成器和鉴别器的损失曲线逐步收敛到较为稳定的状态.

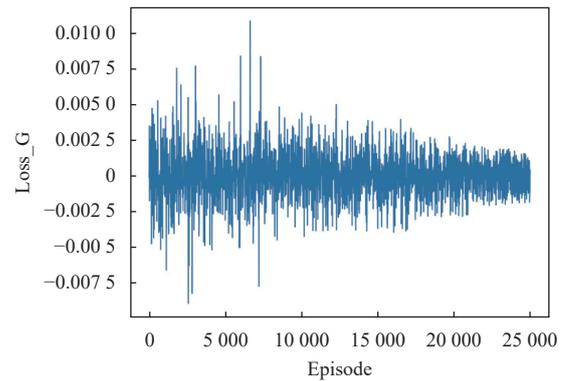


图 4 生成器损失

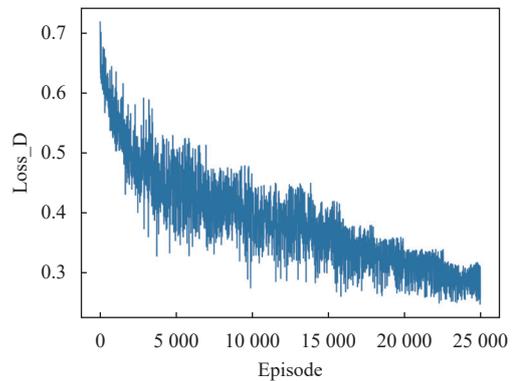


图 5 鉴别器损失

## 4.4 实验结果

### 4.4.1 宏观相似性分析

提出的模型与基线模型在 GeoLife 和 T-drive 数

据集上的宏观相似性度量比较如表 2 所示. 其中值越低, 结果越好. 加粗数据表示最优结果, 下划线表示次优结果. 表 2 中可见, 提出的 LAPGAIL 在大部分宏观相似性指标下表现最好, 即使在某些指标上未表现最好, 但与最好的结果也相差不大. 由于在生成器中考虑了位置相关的动作分布先验知识, LAPGAIL 明显优于其他模型. 基于 GAIL 的方法的大部分指标优于基于 GAN 的方法, 说明了建模人类决策的有效性.

为了更好地说明模型之间的差异, 在图 6、图 7 中可视化了真实和合成轨迹的空间位置分布. 对于每个合成轨迹数据集的热力图, 也计算了其与实际数据集的余弦相似度. 余弦相似度越高, 表明空间分布保留得越好. 对于每个图片, X 轴表示经度, Y 轴表示纬度, CS 表示合成轨迹数据集与真实数据集之间的余弦相似度. 从图 6、图 7 中可以看出, 相比于其他的模型, LAPGAIL 生成合成轨迹数据集的余弦相似度最高. 表

明 LAPGAIL 不仅可以捕获真实的空间分布, 而且还可以生成更加真实的合成轨迹.

#### 4.4.2 微观相似性分析

图 8-图 11 显示了提出的模型和基线模型在两个真实数据集上的 Hausdorff distance 和 edit distance (ED) 比较. Hausdorff distance 测量生成的轨迹数据集和真实数据集之间的差异, 距离越小表示合成轨迹的数据效用越好. ED 度量每条合成轨迹和真实轨迹的相似度, ED 值越小表示合成轨迹与真实轨迹越相似. 图中横坐标表示生成轨迹的数量. 从图 8-图 11 中可以看出, 相较于其他的基线模型, 提出的模型总是可以取得较好的结果. 图 10、图 11 中, 尽管没有取得最好的结果, 但是与最好的结果也相差不大; 从数据集的角度观察, 提出的模型总是可以取得较好的结果, 说明了提出的方法可以从数据中准确的学习到人类迁移规律.

表 2 提出的模型和基线方法在两个移动数据集下的性能比较

Method	GeoLife					T-drive				
	Distance	Radius	DailyLoc	Rank	Exploration	Distance	Radius	DailyLoc	Rank	Exploration
SeqGAN	0.2041	0.6125	0.6512	<u>0.0069</u>	0.2697	0.147	0.5326	0.5723	0.1078	0.2345
MoveSim	0.0096	0.1385	<b>0.0189</b>	0.0181	0.0754	0.1261	0.1997	0.5148	<u>0.0327</u>	0.1278
PateGail	0.0041	<u>0.0273</u>	0.4799	0.0091	0.1317	0.1382	0.1502	0.4924	0.0806	0.1047
GeoGail	<u>0.0029</u>	0.0299	0.2252	0.0077	<u>0.0346</u>	<u>0.0747</u>	<u>0.0983</u>	<u>0.3724</u>	0.0445	<u>0.0303</u>
Our	<b>0.0024</b>	<b>0.027</b>	<u>0.1732</u>	<b>0.0039</b>	<b>0.0259</b>	<b>0.0218</b>	<b>0.0569</b>	<b>0.1491</b>	<b>0.0268</b>	<b>0.0213</b>

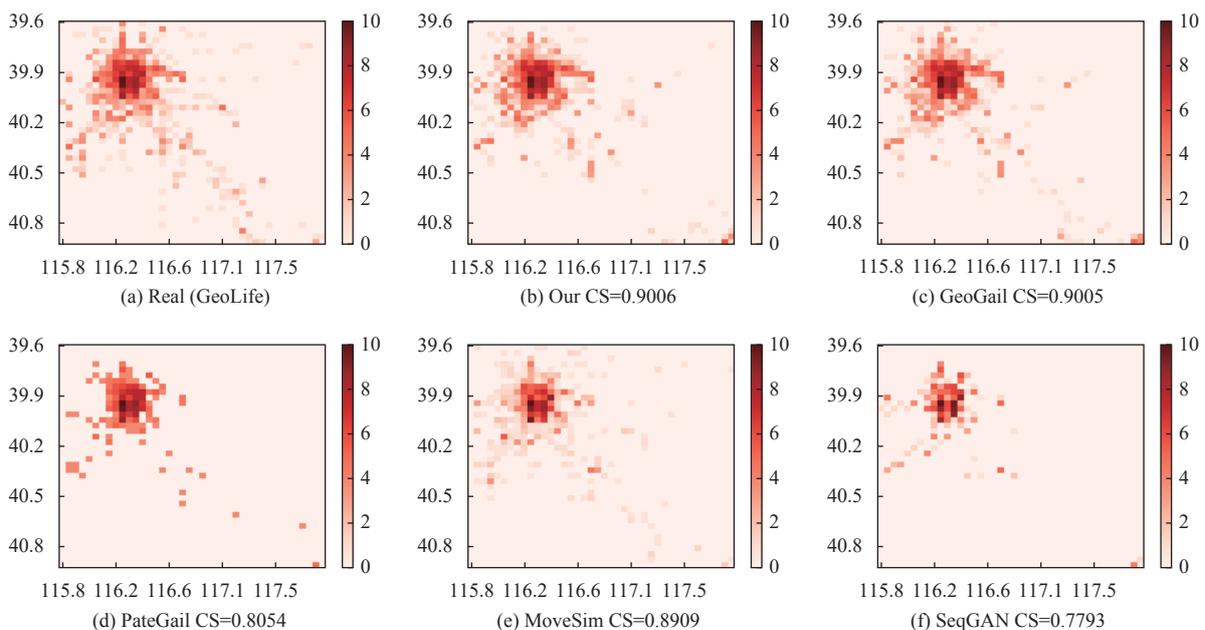


图 6 GeoLife 数据集的真实和合成轨迹的位置分布比较

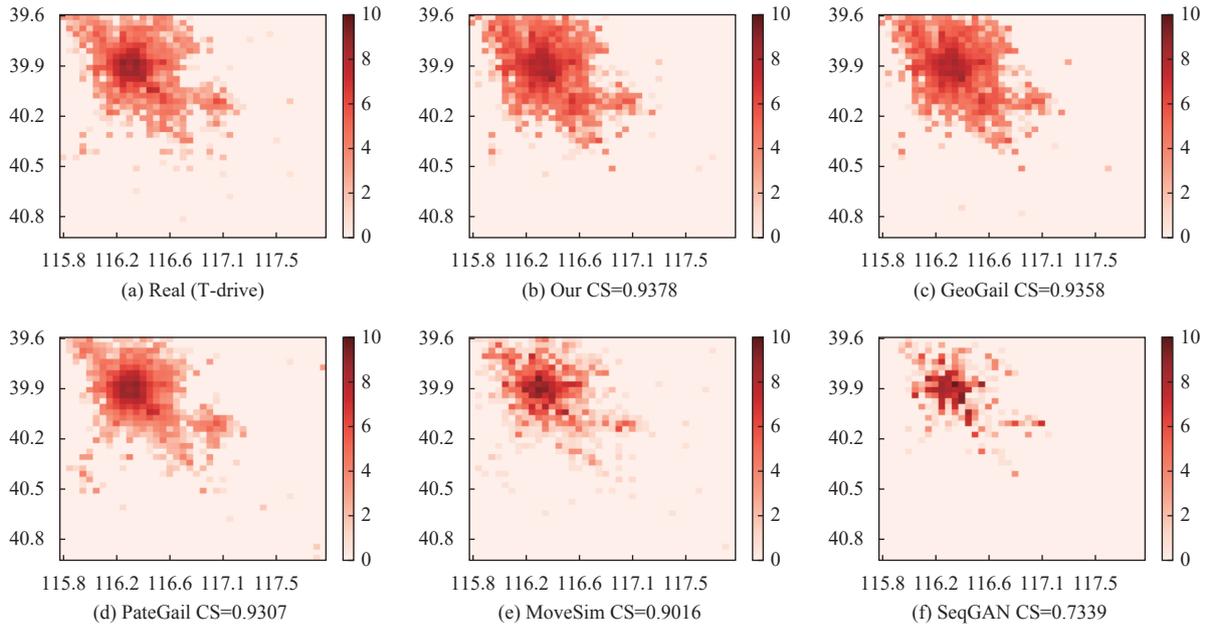


图 7 T-drive 数据集的真实和合成轨迹的位置分布比较

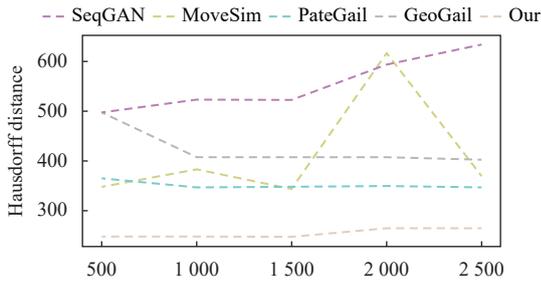


图 8 GeoLife 数据集上的 Hausdorff distance 比较

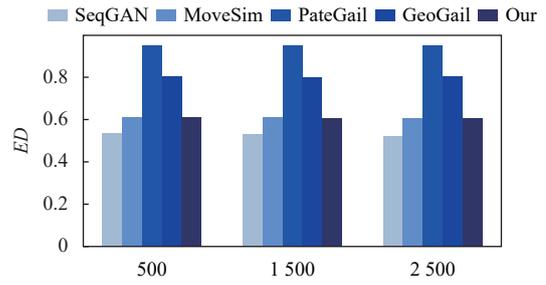


图 11 T-drive 数据集上的 edit distance 比较

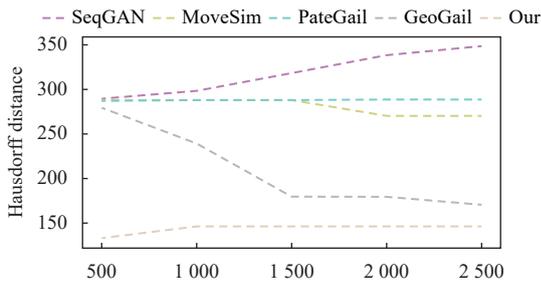


图 9 T-drive 数据集上的 Hausdorff distance 比较

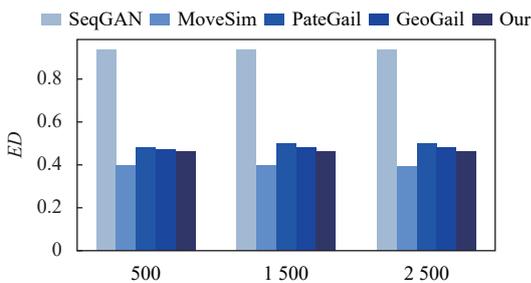


图 10 GeoLife 数据集上的 edit distance 比较

### 4.4.3 可解释模仿学习

为了解释模型学习到了什么知识, 根据 TimeGeo<sup>[20]</sup> 中定义的 3 个具有明确物理意义的统计特征进行了实验. 这 3 个特征能够直观地反映出出行行为的某些方面 (例如: 人们更倾向于去哪些位置), 并与实际生活中的现象相契合. 结果如表 3 所示, 加粗数据表示与真实数据最接近, 每个特征下, 左边表示生成数据的参数值, 右边表示与真实数据相对应的参数差的绝对值. 从表 3 中可以观察到, LAGAIL 合成轨迹的统计特征与真实轨迹的统计特征更接近, 表明它能够更好地拟合真实数据. 随着两个真实数据集的变化, 模型捕获的统计特征也随之变化. 此外, 在提出的模型中, 这些统计特征没有以有监督的方式建模, 表明提出的模型可以自动的学习这些知识.

### 4.4.4 消融实验

为了验证 LAGAIL 中 LocAct 模块和对状态转移

距离约束的有效性,设计了3个LAPGAIL变体,在两个真实的轨迹数据集进行了消融研究.分别是No\_All,表示从LAPGAIL中移除了LocAct模块和状态转移中的距离约束;No\_Loc,表示从LAPGAIL中移除了LocAct模块;No\_Dis表示从LAPGAIL中移除了状态转移中的距离约束.从表4中可以观察到,当删除任意

一个模块时,模型的性能都有不同程度的下降;当增加任意一个模块时,模型的性能都有提升.相比于状态转移中的距离约束,LocAct模块对模型性能的提升最重要.其中,从T-drive数据集集中的Distance和Radius两个空间度量指标上,发现状态转移中的距离约束对改善空间的统计指标很重要.

表3 可解释统计特征比较

Method	GeoLife						T-drive					
	$N_w$		$\beta_1$		$\beta_2$		$N_w$		$\beta_1$		$\beta_2$	
SeqGAN	0.306	2.045	0.24	1.839	0.483	4.886	0.407	11.42	0.162	7.003	0.2927	5.0403
MoveSim	6.911	4.56	3.29	1.211	2.023	3.346	1.523	10.304	0.948	6.217	2.383	2.95
PateGail	0.026	2.325	0.001	2.078	0.022	5.347	<b>10.497</b>	1.33	15.061	7.896	1.494	3.839
GeoGail	4.285	1.934	5.064	2.985	2.424	2.945	24.767	12.94	11.736	4.571	0.532	4.801
Our	<b>3.752</b>	1.401	<b>2.39</b>	0.311	<b>3.023</b>	2.346	20.923	9.096	<b>3.248</b>	3.917	<b>2.474</b>	2.859
Real	2.351	—	2.079	—	5.369	—	11.827	—	7.165	—	5.333	—

表4 消融实验结果比较

Method	GeoLife					T-drive				
	Distance	Radius	DailyLoc	Rank	Exploration	Distance	Radius	DailyLoc	Rank	Exploration
No_all	0.0041	<u>0.0273</u>	0.4799	0.0091	0.1317	0.1382	0.1502	0.4924	0.0806	0.1047
No_Dis	0.0029	0.0281	<u>0.182</u>	0.0071	<u>0.0264</u>	<u>0.0348</u>	<u>0.0655</u>	<u>0.2123</u>	0.0324	<u>0.023</u>
No_Loc	<u>0.0027</u>	0.029	0.2078	<u>0.004</u>	0.0306	0.0487	0.0795	0.3202	<u>0.0319</u>	0.0389
Full model	<b>0.0024</b>	<b>0.027</b>	<b>0.1732</b>	<b>0.0039</b>	<b>0.0259</b>	<b>0.0218</b>	<b>0.0569</b>	<b>0.1491</b>	<b>0.0268</b>	<b>0.0213</b>

#### 4.4.5 下一个位置预测

除了宏观相似性、微观相似性和可解释性方面评估外,还进行了轨迹的下一个位置预测,以评估合成轨迹的效用.具体来说,在两个真实数据集上利用LSTM作为预测模型.使用提出的模型生成的数据、基线模型生成的数据和真实数据分别训练LSTM,并在同一测试集上评估,结果如图12、图13所示.可以观察到提出的模型生成数据的效用超过了其他模型生成的数据,证明了所生成数据在实际应用中的实用性.

成器生成的轨迹更符合原始轨迹的移动规律.此外,设计了一种考虑距离约束的状态转移函数,避免了生成不符合物理运动规律的位置.实验结果表明,提出的方法优于对比基线模型.本文将动作空间简化为4个代表性的动作,未来可以考虑更复杂的动作空间和状态转移,并且将模型拓展到各种应用上.

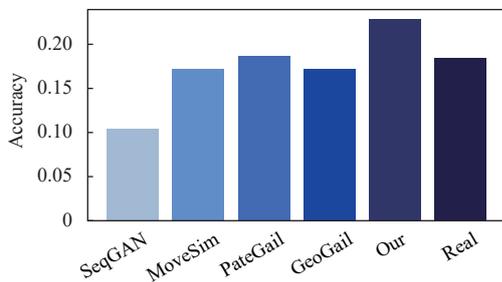


图12 GeoLife数据集上的位置预测比较

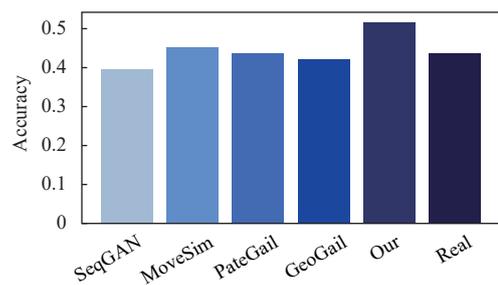


图13 T-drive数据集上的位置预测比较

## 5 结论与展望

本文提出一种新的GAIL轨迹生成方法LAPGAIL.该方法将位置移动规律引入到模型的生成器中,使生

### 参考文献

1 Lai SJ, Farnham A, Ruktanonchai NW, et al. Measuring mobility, disease connectivity and individual risk: A review of using mobile phone data and mHealth for travel medicine. Journal of Travel Medicine, 2019, 26(3): taz019. [doi: 10.1093/jtm/taz019]

- 2 Oliver N, Lepri B, Sterly H, *et al.* Mobile phone data for informing public health actions across the COVID-19 pandemic life cycle. *Science Advances*, 2020, 6(23): eabc0764. [doi: [10.1126/sciadv.abc0764](https://doi.org/10.1126/sciadv.abc0764)]
- 3 Pappalardo L, Cornacchia G, Navarro V, *et al.* A dataset to assess mobility changes in Chile following local quarantines. *Scientific Data*, 2023, 10(1): 6. [doi: [10.1038/s41597-022-01893-3](https://doi.org/10.1038/s41597-022-01893-3)]
- 4 Kraemer MUG, Yang CH, Gutierrez B, *et al.* The effect of human mobility and control measures on the COVID-19 epidemic in China. *Science*, 2020, 368(6490): 493–497. [doi: [10.1126/science.abb4218](https://doi.org/10.1126/science.abb4218)]
- 5 Kapp A, Hansmeyer J, Mihaljević H. Generative models for synthetic urban mobility data: A systematic literature review. *ACM Computing Surveys*, 2024, 56(4): 93. [doi: [10.1145/3610224](https://doi.org/10.1145/3610224)]
- 6 Kong XJ, Chen Q, Hou ML, *et al.* Mobility trajectory generation: A survey. *Artificial Intelligence Review*, 2023, 56(3): 3057–3098. [doi: [10.1007/s10462-023-10598-x](https://doi.org/10.1007/s10462-023-10598-x)]
- 7 Wei H, Chen CC, Liu C, *et al.* Learning to simulate on sparse trajectory data. *Proceedings of the 2021 European Conference on Machine Learning and Knowledge Discovery in Databases: Applied Data Science Track*. Ghent: Springer, 2021. 530–545.
- 8 Choi S, Kim J, Yeo H. TrajGAIL: Generating urban vehicle trajectories using generative adversarial imitation learning. *Transportation Research Part C: Emerging Technologies*, 2021, 128: 103091. [doi: [10.1016/j.trc.2021.103091](https://doi.org/10.1016/j.trc.2021.103091)]
- 9 Wang HD, Gao CZ, Wu YC, *et al.* PateGail: A privacy-preserving mobility trajectory generator with imitation learning. *Proceedings of the 37th AAAI Conference on Artificial Intelligence*. Washington: AAAI, 2023. 14539–14547. [doi: [10.1609/aaai.v37i12.26700](https://doi.org/10.1609/aaai.v37i12.26700)]
- 10 Wu YC, Wang HD, Gao CZ, *et al.* GeoGail: A model-based imitation learning framework for human trajectory synthesizing. *ACM Transactions on Knowledge Discovery from Data*, 2025, 19(1): 20. [doi: [10.1145/3699961](https://doi.org/10.1145/3699961)]
- 11 Lu J, Gong PH, Ye JP, *et al.* A survey on machine learning from few samples. *Pattern Recognition*, 2023, 193: 109480. [doi: [10.1016/j.patcog.2023.109480](https://doi.org/10.1016/j.patcog.2023.109480)]
- 12 Chen RN, Hu J, Xu WC. An RRT-Dijkstra-based path planning strategy for autonomous vehicles. *Applied Sciences*, 2022, 12(23): 11982. [doi: [10.3390/app122311982](https://doi.org/10.3390/app122311982)]
- 13 Song CM, Koren T, Wang P, *et al.* Modelling the scaling properties of human mobility. *Nature Physics*, 2010, 6(10): 818–823. [doi: [10.1038/nphys1760](https://doi.org/10.1038/nphys1760)]
- 14 Ross S, Bagnell D. Efficient reductions for imitation learning. *Proceedings of the 13th International Conference on Artificial Intelligence and Statistics*. Sardinia: JMLR, 2010. 661–668.
- 15 Ross S, Gordon GJ, Bagnell D. A reduction of imitation learning and structured prediction to no-regret online learning. *Proceedings of the 14th International Conference on Artificial Intelligence and Statistics*. Fort Lauderdale: JMLR, 2011. 627–635.
- 16 Feng J, Yang ZY, Xu FL, *et al.* Learning to simulate human mobility. *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. New York: ACM, 2020. 3426–3433. [doi: [10.1145/3394486.3412862](https://doi.org/10.1145/3394486.3412862)]
- 17 Zheng Y, Xie X, Ma WY. GeoLife: A collaborative social networking service among user, location and trajectory. *IEEE Data Engineering Bulletin*, 2010, 33(2): 32–39.
- 18 Yuan J, Zheng Y, Zhang CY, *et al.* T-drive: Driving directions based on taxi trajectories. *Proceedings of the 18th SIGSPATIAL International Conference on Advances in Geographic Information Systems*. San Jose: ACM, 2010. 99–108.
- 19 Yu LT, Zhang WN, Wang J, *et al.* SeqGAN: Sequence generative adversarial nets with policy gradient. *Proceedings of the 31st AAAI Conference on Artificial Intelligence*. San Francisco: AAAI, 2017.
- 20 Jiang S, Yang YX, Gupta S, *et al.* The TimeGeo modeling framework for urban mobility without travel surveys. *Proceedings of the National Academy of Sciences of the United States of America*, 2016, 113(37): E5370–E5378. [doi: [10.1073/pnas.1524261113](https://doi.org/10.1073/pnas.1524261113)]

(校对责编: 张重毅)