arXiv:2603.00936v1 [cs.RO] 1 Mar 2026

DRIFT：基于扩散的轨迹规则推断

赵金阳、郑汉东、钟延究、张强、吴舜宇、康宇

摘要—**在非结构化环境中为移动机器人生成轨迹，面临一个关键难题：如何兼顾安全执行所需的运动学平滑性与细粒度任务所需的终端精度。现有生成式规划器往往难以权衡二者，生成的路径要么平滑但不精确，要么几何精度高却运动不稳定。为解决上述不足，本文提出 DRIFT（基于扩散的轨迹规则推断），这是一种条件扩散框架，通过整合两种互补的归纳偏置来生成高保真参考轨迹。首先，通过基于 GNN 的结构化场景感知（SSP）模块实现的关系归纳偏置，对全局拓扑约束进行编码，以确保整体平滑性。其次，通过新型图条件时序感知 GRU（GTGRU）实现的时间注意力偏置，会动态关注稀疏分布的障碍物和目标，从而实现精确的局部机动。最终，定量结果表明，DRIFT 调和了这些相互冲突的目标，实现了厘米级的模仿保真度（最终位移误差为 0.041 米）和具有竞争力的平滑性（加加速度为 27.19）。这种平衡为下游控制提供了高度可执行的参考规划。**

索引词—**移动机器人、运动规划、轨迹生成、扩散模型，**

I. 引言

在大规模、非结构化环境中生成安全、平滑且可行的轨迹，是自主移动机器人的先决条件 [1], [2]。尽管感知驱动的无地图方法在为开放空间导航生成可行路径方面已迅速发展 [3]–[7], ，但对接、预抓取定位或近距离机动等细粒度任务仍极具挑战。在这些场景中，轨迹的有效性不再仅由可达性决定，还取决于能否同时满足两个严格且往往相互冲突的目标：确保安全执行的运动学平滑性，以及实现精确任务完成的终端精度 [8]–[10]。

对于细粒度操作或对接任务，生成的参考轨迹必须在严格的端点约束下，以较高的几何精度收敛至目标位姿。同时，为了使下游低级控制器能够稳定跟踪，并确保在共享环境中的行为可预测，轨迹必须通过最小化高阶运动导数来保持运动学平滑 [11]然而，这两个在基于学习的规划中，目标往往存在内在冲突。严格施加终端约束通常会导致接近目标时出现高频调整，进而造成速度或加加速度曲线不稳定。相反，若优先考虑全局平滑性，往往会产生不可忽视的终端位移误差。这种精度-平滑性权衡是当前无地图轨迹生成方法尚未解决的根本瓶颈。

现有的数据驱动方法通常通过两种截然不同的范式来应对这一权衡。经典生成模型或嵌入优化的网络优先考虑严格的几何约束和终端精度 [12]–[14]。然而，尽管这类方法能够有效满足端点条件，如此僵化的边界约束往往会引入运动学不连续性，生成的轨迹难以由低级控制器平滑跟踪。相比之下，近期的基于扩散的策略擅长合成全局连贯且运动学可行的运动，因此非常适用于无约束导航 [15]–[19]。然而，由于其随机性以及对静态条件化的依赖，这些模型通常难以实现细粒度的终端控制，往往无法收敛至高保真机动所需的精确目标状态。因此，实现“高保真生成”——即同时满足运动学平滑性和几何精度——仍是一项亟待解决的挑战。

为应对这一挑战，我们提出 DRIFT（基于扩散的轨迹规则推断），一种用于高保真轨迹生成的条件生成框架。DRIFT 将架构归纳偏置显式融入扩散过程，从结构上将全局拓扑推理与细粒度局部机动解耦。这一设计使规划器能够在统一的生成框架中兼顾运动学平滑性与终端精度。

具体而言，DRIFT 通过基于图神经网络的结构化场景感知（SSP）模块，融入关系归纳偏置，以增强全局运动学一致性。针对缺乏拓扑上下文常导致的运动学不稳定性，SSP 将无结构点云 [20]–[22] 编码为潜在场景图 [23]–[26]。这种结构化表示能够显式捕捉环境可供性，确保轨迹在全局上保持连贯，并主动与目标位姿对齐，从而从结构上避免高加加速度伪影。

此外，为确保终止状态保真度，DRIFT 通过一种新颖的图条件化时间感知 GRU（GTGRU）引入时间注意力偏置。我们认为，标准扩散规划器之所以出现终止偏差，是因为其依赖静态条件化，无法适应去噪过程中细粒度的约束。通过整合稀疏交叉注意力，GTGRU 使生成器能够在每个时间步动态关注关键障碍物和目标状态。这一机制确保生成的

本研究l̂ǎšu国家自然科学基金委员会（项目编号：72501093、92367206、92467302）和中国博士后科学基金会（2024T012AH、2025M781632）的资助（通讯作者：郑汉东、钟延究。）

赵金阳、郑汉东、YanjiuZhong、张强和康宇来自合肥工业大学管理学院、教育部智能决策与信息系统技术工程研究中心，地址为中国安徽省合肥市，邮编230009。吴舜宇来自上海交通大学自动化系，地址为中国上海市，邮编200240（电子邮箱：2023213574@mail.hfut.edu.cn；zhenghandong@hfut.edu.cn；zhongyanjiu@sjtu.edu.cn；qiang zhang@hfut.edu.cn；shunyuwu@sjtu.edu.cn；kangduyu@hfut.edu.cn）。

参考轨迹能够精确收敛至目标位姿，同时遵循局部几何约束，从而在杂乱环境中有效平衡精度与平滑性 [6], [27]–[31]。

总之，本工作的主要贡献如下：

- 提出 DRIFT，一种条件扩散轨迹生成框架，能够有效协调非结构化环境中轨迹生成所面临的几何精度与运动学平滑性之间的关键权衡。
- 通过基于图神经网络的结构化感知模块引入关系归纳偏置，该模块对全局场景拓扑进行编码，以确保整体运动学连贯性和可通行性。
- 设计了时间注意力偏置机制，采用图条件化时间感知 GRU（GTGRU），从而能够动态关注细粒度约束，实现厘米级终端保真度。

II. 相关工作与背景

A. 面向轨迹生成的结构化场景编码

非结构化环境的表示对于后续轨迹生成的保真度至关重要。主流感知方法，例如使用卷积神经网络的语义分割或通过神经辐射场（NeRF）进行的几何重建，已在稠密场景描述方面实现了高保真度 [32]–[35]。然而，这些基于网格或隐式表示的架构归纳偏置——尤其是其局部性与平移不变性——本质上不适合建模全局拓扑关系。因此，它们难以捕捉一致性规划所需的长程连通性与空间可供性。为弥合这一差距，图神经网络提供了一种强有力的范式。通过将环境实体显式建模为节点、将空间约束建模为边，图神经网络独特的关系归纳偏置能够从原始感知中提取拓扑一致的上下文嵌入 [23]–[25], [36], [37]，从而为下游扩散生成器提供结构化基础。

B. 面向运动规划的生成模型

基于学习的轨迹生成经历了从早期的条件变分自编码器（CVAEs） [38],生成对抗网络 [39]–[42] 和 Transformer [43] ，发展到近期的去噪扩散概率模型（DDPM） [3], [16], [19]。早期生成模型和序列预测器虽然能够捕捉运动分布，但往往存在训练不稳定或运动学不连续的问题。相比之下，基于扩散的规划器（如 Diffuser [15] 和 DTG [18],）擅长合成长时域、连贯的轨迹。然而，现有扩散策略的一个关键瓶颈在于依赖静态条件化：环境上下文在生成前被编码为固定向量。这种范式通常不适用于细粒度终端任务，因为它无法使模型在迭代去噪过程中动态关注局部几何约束。

C. 运动规划中的平滑性与精度优化

在非结构化环境中生成能够有效兼顾运动学可行性与几何精度的轨迹，仍是一项根本性挑战。传统的基于优化的规划器（例如 MPC） [12]–[14] 擅长严格满足终端约束和安全边界。然而，这些方法往往受限于较高的计算延迟，且容易陷入局部最优。相比之下，基于学习的策略（例如行为克隆） [10], [44], [45]推理效率高，但往往难以捕捉专家机动的多模态特性。这一局限通常表现为欠拟合与强制过拟合之间的权衡：欠拟合会导致终端空间漂移，而强制过拟合则会引发高频抖动，进而损害下游跟踪稳定性。目前，鲜有框架能够仅凭生成模型的架构归纳偏置有效调和运动学连贯性与终端精度之间的矛盾，而无需依赖计算开销巨大的在线优化。

总而言之，先前的研究在结构化场景表示、生成式轨迹建模和运动优化方面取得了显著进展。然而，缺乏能够显式整合关系场景结构与时间自适应生成过程的统一框架，仍持续限制着细粒度任务中的高保真轨迹生成。这一观察促使我们开发下一节介绍的方法。

III. 问题表述

我们将无地图轨迹生成任务形式化为学习条件分布 $p_\theta(\tau|\mathcal{O})$，以合成高保真参考规划。如图 1 所示，在时间步 t，观测 $\mathcal{O}_t$ 由局部激光雷达点云$\mathbf{P}_t \in \mathbb{R}^{N\times 3}$、机器人的历史速度序列$\mathbf{v}_t \in \mathbb{R}^{H_v\times 2}$以及局部目标坐标$\mathbf{g}_t \in \mathbb{R}^2$组成。目标是生成未来轨迹 $\tau = (\mathbf{w}_1, \mathbf{w}_2, \ldots, \mathbf{w}_M)$，其中$\mathbf{w}_i \in \mathbb{R}^2$ 表示机器人局部坐标系中的规划航点。

不同于仅最小化几何重建误差（例如豪斯多夫距离）的标准模仿学习，用于精细操作的有效参考规划必须满足两组内在约束：

- 全局拓扑一致性（$\mathcal{C}_{global}$）：轨迹必须在环境拓扑方面运动学连贯且无碰撞。这对应于最小化平滑度代价 $\mathcal{L}_{smooth}$ 和碰撞代价$\mathcal{L}_{coll}$。
- 终端状态保真度（$\mathcal{C}_{local}$）：轨迹必须以最小位移精确收敛至目标状态，因此需要将终端误差 $\mathcal{L}_{term}$降至最低。

数学上，令 $\hat{\tau} = \pi_\theta(\mathcal{O}_t)$ 表示由策略生成的轨迹。通过最小化复合目标函数来学习最优参数 θ^*：

$$\theta^* = \arg\min_\theta \mathbb{E}_{\tau_{gt}\sim\mathcal{D}}\Big[\mathcal{L}_{\text{imit}}(\hat{\tau}, \tau_{gt}) + \lambda_1\mathcal{C}_{global}(\hat{\tau}) + \lambda_2\mathcal{C}_{local}(\hat{\tau})\Big], \tag{1}$$

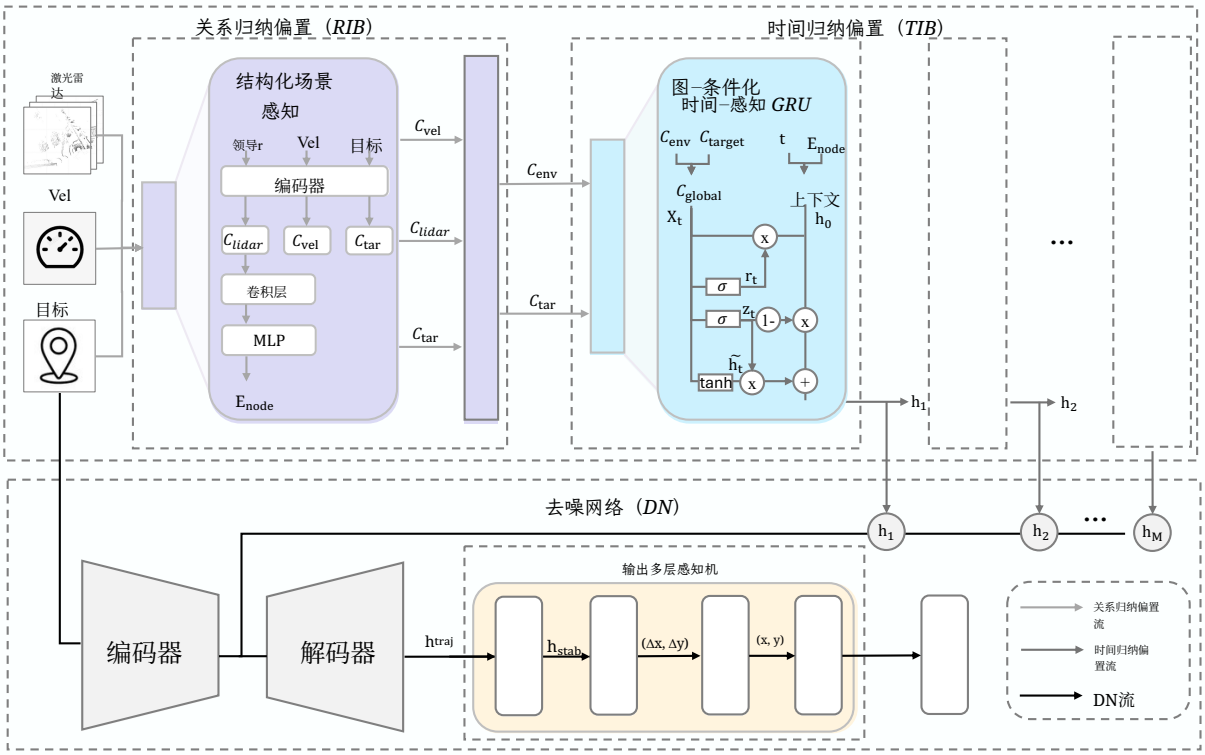

图1：DRIFT融合关系拓扑偏置（SSP）与时间注意力偏置（GTGRU），以生成高保真参考规划。随后，去噪网络（DN）基于这些结构化编码迭代优化轨迹，在平滑性与精度之间取得平衡。

其中 $\lambda_{1,\ 2}$ 为平衡各项约束的动态权重因子。

然而，由于障碍物规避具有不可微性，且平滑性与精度相互冲突，直接优化式(1)十分困难。为此，DRIFT采用“架构即正则化”方法。我们并非仅依赖损失约束，而是将特定归纳偏置直接嵌入网络架构。具体而言，SSP 模块注入关系归纳偏置，通过编码场景拓扑 E_{node}来隐式满足 $\mathcal{C}_{global}$，而图条件时间感知GRU（GTGRU）注入时间注意力偏置，通过动态关注细粒度终端约束来强制实现 $\mathcal{C}_{local}$。

IV. 方法论

A. 概述

所提出的 DRIFT 框架将无地图导航规划重新表述为条件轨迹生成过程，明确将这一挑战解耦为全局拓扑推理和局部细粒度细化。为协调运动学平滑性与终端精度之间固有的权衡，该架构融入了两种正交的架构归纳偏置。首先，SSP 模块注入关系归纳偏置，将无结构点云编码为潜在场景图，以确保全局拓扑一致性。其次，循环去噪生成器（RDG）通过自回归去噪机制引入时间注意力偏置。该生成器由一种新颖的图条件时间感知 GRU（GTGRU）实现，使模型能够动态关注关键终端约束，从而实现高保真收敛。

B. 关系归纳偏置：结构化场景感知

为了实例化关系归纳偏置，SSP 模块被设计用于从非结构化输入中提取拓扑一致表示。与将空间数据压缩为全局向量的基于投影的方法不同，SSP 显式地将局部环境建模为潜在图 $\mathcal{G} = (\mathcal{V}, \mathcal{E})$，以推理几何可供性。

该流程首先处理原始激光雷达点云 $\mathbf{P}_t$。为了在计算效率与局部细节之间取得平衡，我们采用基于体素的下采样，将点云离散为局部区域，并将每个非空体素视为一个图节点$v_i \in \mathcal{V}$（图 2）。初始节点特征 $\mathbf{x}_i$ 编码质心坐标和局部点密度。拓扑连通性通过在特征空间中经由 k-最近邻（k-NN）构建边 $\mathcal{E}$ 来建立，从而即使在稀疏区域也能确保稳健的消息传递。

该潜在图由一个由多个 EdgeConv层堆叠而成的图神经网络骨干网络处理 [21]。选择该网络是因为它能够通过处理边特征来捕捉局部几何结构。节点特征更新定义为对局部邻域 $\mathcal{N}(v_i)$ 进行对称聚合：

$$\mathbf{h}_i^{(l+1)} = \max_{j \in \mathcal{N}(v_i)} \text{MLP}^{(l)} \left(\mathbf{h}_i^{(l)} \oplus (\mathbf{h}_j^{(l)} - \mathbf{h}_i^{(l)}) \right), \quad (2)$$

其中，$\oplus$ 表示特征拼接，$\mathbf{h}_i^{(l)}$ 表示第 l 层节点 v_i 的隐藏特征向量（其中 $\mathbf{h}_i^{(0)} = \mathbf{x}_i$）。术语（$\mathbf{h}_j^{(l)} - \mathbf{h}_i^{(l)}$）明确捕捉了质心节点 i 与其邻居 j 之间的相对空间关系。此操作确保学习到的表征能够捕捉不受全局平移影响的局部几何细节。

关键的是，SSP 模块生成两种不同的表示，以支持我们框架的双重约束：

- 节点级嵌入（E_{node}）：最终图神经网络层的密集特征保留了精细的空间细节，供后续注意力机制查询局部障碍物。

Algo算法 1 结构化场景感知（SSP）模块 dule

1：生成图嵌入（$\mathcal{O}_l$；k，L） 2：输入：原始点集/观测 $\mathcal{O}_l$，邻居数量 k，图神经网络深度 L3：输出：节点嵌入 E_{node}，全局上下文 c_{lidar}4：1. 动态图构建 5：$V_{\text{sparse}} \leftarrow$体素下采样（$\mathcal{O}_l$） 6：$\mathcal{E} \leftarrow$ k近邻（V_{sparse}，k） 7：$h^{(0)} \leftarrow$ 初始特征（V_{sparse}） 8：$\mathcal{G} \leftarrow$（V_{sparse}，$h^{(0)}$，$\mathcal{E}$） 9：2. 图神经网络特征传播（RGE） 10：对 $l = 0$ 至 $L-1$ 执行 11：对每个节点 $v \in V_{\text{sparse}}$ 执行 12 $h_{\text{edge}} \leftarrow \bigoplus_{u \in \mathcal{N}_v} \phi^{(l)}\left(h_v^{(l)} \oplus h_u^{(l)} - h_v^{(l)}\right)$：（） 13 $h_v^{(l+1)} \leftarrow f_\theta^l\left(h_v^{(l)} \; h_{\text{edge}}\right)$ 多层感知机（）：（），14：结束循环 15：结束循环 16：3. 生成输出 17：$E_{\text{node}} \leftarrow \{h_v^{(L)}\}_{v \in V_{\text{sparse}}}$18：$c_{\text{lidar}} \leftarrow$ 全局最大池化（E_{node}） 19：返回 E_{node}，c_{lidar}

- 环境上下文（c_{env}）：通过将池化图特征 $c_{lidar} = \text{MaxPool}(E_{node})$与机器人的历史运动学状态融合，得到全局上下文向量。速度历史 $\mathbf{v}_t$ 通过一维卷积神经网络编码为 c_{vel}，并融合如下：

$$c_{env} = \text{MLP}_{\text{fuse}}(c_{lidar} \oplus c_{vel}). \tag{3}$$

值得注意的是，不同于将目标融入全局上下文的先前研究，我们有意将目标 g_t 排除在c_{env}之外。该设计实现了结构解耦，确保感知模块纯粹专注于环境可通行性（满足 $\mathcal{C}_{global}$），而目标引导则由时序生成过程动态处理。

C. 时间归纳偏置：循环去噪生成器

此外，为了确保终端状态保真度（$\mathcal{C}_{local}$），该框架通过循环去噪生成器（RDG）引入了时间注意力偏置。SSP 模块提供静态全局地图，而扩散去噪过程需要动态适应随预测时域变化的细粒度约束

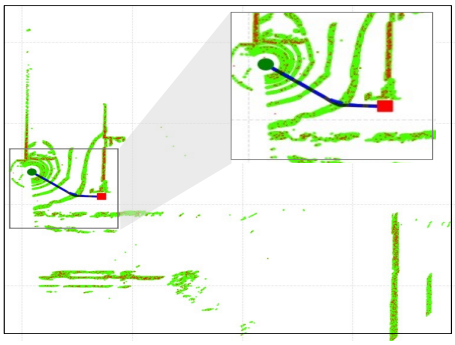

图 2：体素下采样将密集的激光雷达点云（绿色）转换为稀疏图节点（红色）（算法 1），降低计算成本，并为图神经网络关系推理生成结构化拓扑。

。RDG 采用新颖的图条件时间感知 GRU（GTGRU）作为骨干网络，将轨迹生成重新表述为一种以拓扑嵌入为条件的序列到序列翻译任务。

具体而言，在每个扩散步 k，含噪轨迹$\mathbf{x}^{(k)}$ 都会以自回归方式进行处理。对于第 m 个航点 $\mathbf{w}_m$，GTGRU 单元通过整合三个关键信息流来更新其隐状态 $\mathbf{h}_m$：

1) 动态障碍物注意力：为解决局部碰撞风险，我们采用稀疏交叉注意力机制。与静态池化不同，当前隐状态 $\mathbf{h}_{m-1}$ 作为查询，从 SSP 生成的节点嵌入E_{node}（键/值）中检索相关空间特征。由此产生动态上下文向量 $\mathbf{d}_m$，专门聚焦于与当前时域步相关的障碍物：

$$\mathbf{d}_m = \text{Attention}(\mathbf{Q} = \mathbf{h}_{m-1}, \mathbf{K} = E_{node}, \mathbf{V} = E_{node}). \tag{4}$$

该机制使规划器仅在轨迹接近特定图节点（例如门框或障碍物边缘）时才“注视”它们，从而在避免过平滑的同时确保运动学间隙。

2) 目标驱动门控：为确保精确收敛到目标，目标编码 c_{target} 与全局上下文 c_{env} 及时间嵌入 t_{embed} 融合，形成条件向量 $\mathbf{c}_{cond}$。该向量被注入每个循环步骤，直接调制 GRU 的更新门 $\mathbf{z}_m$ 和重置门$\mathbf{r}_m$：

$$\begin{aligned} \mathbf{z}_m &= \sigma(W_z \mathbf{w}_m + U_z \mathbf{h}_{m-1} + V_z \mathbf{d}_m + C_z \mathbf{c}_{cond}), \\ \mathbf{h}_m &= (1 - \mathbf{z}_m) \odot \mathbf{h}_{m-1} + \mathbf{z}_m \odot \tilde{\mathbf{h}}_m. \end{aligned} \tag{5}$$

通过持续将 c_{target} 注入门控机制，网络在整个长时域生成过程中保持通向终端状态的强梯度流，从而有效最小化终点位移误差 $\mathcal{L}_{term}$。

D. 训练目标与课程安排

为落实所提出的架构归纳偏置，我们采用基于预测的训练策略。与预测噪声残差 ϵ 的标准扩散模型不同，我们的生成器G_θ 被参数化为直接预测无噪声轨迹 $\hat{}\tau = \mathbf{x}_0$

。这种形式使我们能够直接在输出空间中应用可微几何与运动学约束。

全局目标 $\mathcal{L}_{total}$ 将标准扩散去噪损失 $\mathcal{L}_{simple}$ 与一组辅助约束损失$\mathcal{L}_{aux}$相结合，并由课程调度器动态平衡：

$$\mathcal{L}_{total} = \mathcal{L}_{simple}(\epsilon, \epsilon_\theta) + \sum_k \lambda_k(e) \cdot \mathcal{L}_k(\hat{\tau}, \tau_{gt}, \mathcal{O}_t), \quad (6)$$

其中 e 表示当前训练轮次。辅助损失旨在满足第 III 节中定义的双重约束：

1) 模仿保真度（$\mathcal{L}_{imit}$）：为满足终端状态保真度（$\mathcal{C}_{local}$）并捕捉专家意图，我们最小化一种复合几何距离，该距离由 Hausdorff 距离、动态时间规整（DTW）和端点均方误差构成：

$$\mathcal{L}_{imit} = \mathcal{L}_{Haus}(\hat{\tau}, \tau_{gt}) + \mathcal{L}_{DTW}(\hat{\tau}, \tau_{gt}) + \|\hat{\mathbf{w}}_M - \mathbf{g}_t\|^2. \quad (7)$$

2) 运动学连贯性（$\mathcal{L}_{smooth}$）：为确保全局拓扑一致性（$\mathcal{C}_{global}$），我们明确惩罚高频抖动。平滑损失通过最大化相邻速度向量 $\mathbf{v}_i = \mathbf{w}_{i+1} - \mathbf{w}_i$之间的余弦相似度，来鼓励方向连续性：

$$\mathcal{L}_{smooth} = \mathbb{E}_i \left[1 - \frac{\mathbf{v}_i \cdot \mathbf{v}_{i+1}}{\|\mathbf{v}_i\|_2 \|\mathbf{v}_{i+1}\|_2 + \xi} \right]. \quad (8)$$

3) 安全约束（$\mathcal{L}_{coll}$）：对于任何超出障碍点 $\mathbf{o}_j \in \mathbf{P}_t$ 安全半径 r_{safe} 的航点$\mathbf{w}_i$，我们施加软惩罚：

$$\mathcal{L}_{coll} = \sum_{i,j} \max\left(0, r_{safe} - \|\mathbf{w}_i - \mathbf{o}_j\|_2\right)^2. \quad (9)$$

4）课程策略：我们通过 $\lambda_k(e)$ 实施两阶段课程策略。在初始的模仿阶段（$e < E_{stage1}$），权重优先考虑 $\mathcal{L}_{imit}$，以建立有效的轨迹流形。在后续的精炼阶段（$e \geq E_{stage1}$），我们大幅提高 $\mathcal{L}_{smooth}$ 和 $\mathcal{L}_{coll}$ 的权重（例如，将 λ_{coll} 增加 $3\times$）。该策略引导模型从学习基本可达性，逐步转向精炼高保真、无碰撞且适用于下游控制的规划方案。

V. 实验

A. 实验设置

我们使用由配备 3Hz VLP-16激光雷达的 Husky机器人采集的大规模室外导航数据集（来自[3], ）。按照标准协议 [3], ，观测输入包含最近的 $C_l = 3$ 个激光雷达帧和 $C_v = 10$ 个速度帧。通过 A*规划器生成真值轨迹，并将轨迹阈值设为 15m，包含 $H = 16$ 个航点。训练时在 60m 范围内采样目标，测试时则在 > 50m 范围内采样，以评估长时域生成。与采用 0.08m 体素的 PointCNN 的 DTG 基线不同，我们的感知编码器采用更粗的 0.2m 体素下采样，并结合

借助 k-NN（$k = 8$）图构建器以显式保持拓扑连通性。所有模型均在 NVIDIA RTX 3090 GPU 上训练。

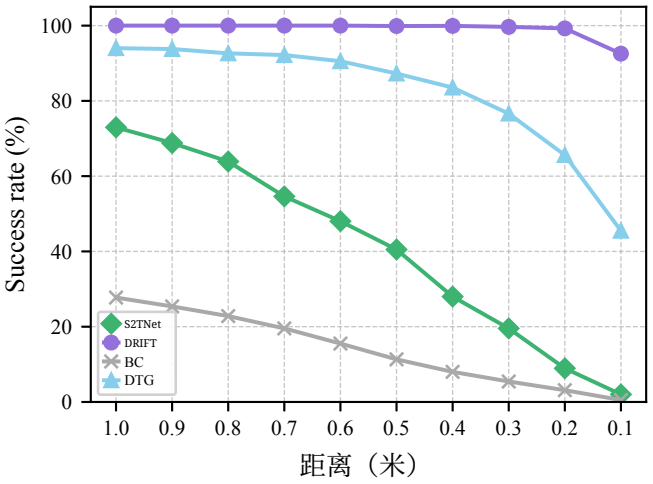

图 3：近距离对接的终端精度比较。我们的方法 DRIFT（紫色），在 0.1 米处的成功率保持在 92.55%，而 DTG 基线（蓝色）则失败（45.49%）。这一结果表明，DRIFT 能够通过实现高精度局部机动，解决“精度-平滑性权衡”。

算法 2 使用 GTGRUCell 的 DRIFT 去噪步骤

DENOISINGSTEP(h_{prev}, x_{prev}, p_t^{curr}, E_{node}, c_{target}, t_{embed})

1. 稀疏交叉注意力

$Q \leftarrow$ 多层感知机$_Q(h_{\text{prev}})$

$K, V \leftarrow$ 多层感知机$_K(E_{\text{node}})$, 多层感知机$_V(E_{\text{node}})$

$\mathcal{N}_k \leftarrow$ k近邻$(p_t^{\text{curr}}, E_{\text{node}}, k_{\text{env}})$

$\alpha \leftarrow \text{Softmax}(\text{相似度}(Q, K[\mathcal{N}_k]))$

$d_i \leftarrow \sum_{j \in \mathcal{N}_k} \alpha_j V_j$

2. 门控循环单元（GTGRU）更新

$x_{\text{in}} \leftarrow$ 点嵌入(x_{prev}) +目标投影(c_{target})

$z_t \leftarrow \sigma\left(W_z x_{\text{in}} + U_z h_{\text{prev}} + V_z d_i + \dots\right)$

$r_t \leftarrow \sigma\left(W_r x_{\text{in}} + U_r h_{\text{prev}} + V_r d_i + \dots\right)$

$\tilde{h}_i \leftarrow$ 双曲正切 $\left(W_h x_{\text{in}} + U_h(r_t \odot h_{\text{prev}}) + \dots\right)$

$h_i \leftarrow (1 - z_t) \odot h_{\text{prev}} + z_t \odot \tilde{h}_i$

3. 航点预测

$w_i^0 \leftarrow$多层感知机$_{\text{out}}(h_i)$

返回 h_i, w_i^0

1) 数据集与挑战协议：该数据集被划分为空间上互不相交的训练区域与测试区域。为严格压力测试生成保真度，我们依据四项极端几何与运动学阈值筛选测试划分，构建了**挑战子集**：

- 空间狭窄：可通行宽度为 < 2.0 米，需要精确贴合边界。
- 高密度障碍物：障碍物占用率为 $> 15\%$（半径 3.0 米），需要精细的路径生成。
- 高动态性：专家轨迹加加速度为 > 5.0 米/秒$_3$，体现了激进的规避机动。
- 拓扑复杂性：专家路径与A*路径长度比为 $\gg 1$，这表明存在超越欧几里得启发式的潜在导航规则。

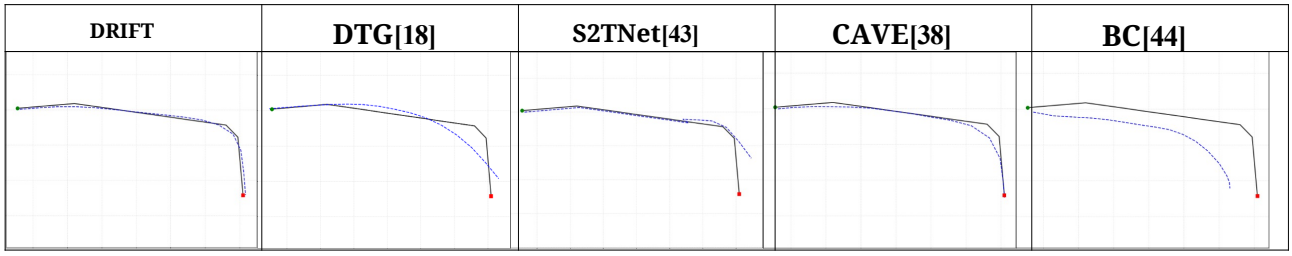

图 4：各模型预测的轨迹（深色）与真实轨迹（浅灰色）对比：DTG 的轨迹平滑，但存在偏差且未能到达终点；CAVE 和 BC 的表现则较为不稳定或不够精确。DRIFT 化解了精度与平滑度之间的权衡，在保持平滑的同时与真实轨迹相符。

2）基线方法：我们将 DRIFT 与不同学习范式中的代表性方法进行比较，以验证其在无地图轨迹生成任务中的优势。优化型规划器（例如模型预测控制）不在比较范围内，因为它们依赖显式地图构建，而这不属于本端到端学习研究的范畴。

- BC（行为克隆） [44]：一种基础的模仿学习基线，采用确定性的感知到动作映射。尽管近期理论分析表明，它在特定条件下具有最优性，但在我们的上下文中，它是衡量几何拟合性能的标准基准。

- CAVE [38] （条件变分自编码器）：一种经典的生成式基线。在轨迹合成中，变分自编码器通常会生成几何形态多样、但运动学上不连贯（加加速度较高）的路径，代表着“高精度、低平滑度”的极端情况。
- S2TNet [43] （时空变换器） [43]：一种利用 Transformer 建模复杂交互的最先进轨迹预测器。它是面向精度架构的高性能基线。
- DTG [18] （基于扩散）：一种用于导航的最先进扩散策略。尽管它擅长生成平滑、自然的路径，但依赖静态条件，通常缺乏对接任务所需的细粒度终端保真度。它代表了高平滑度、低精度这一极端。

3）评估指标：为了严格量化生成的参考规划 τ 的质量，我们从三个维度采用了一套全面的评估指标：

- 几何保真度：最终位移误差（最终位移误差）测量最后一个生成航点$\mathbf{w}_M$ 与局部目标 g 之间的欧几里得距离，用于量化终端精度（$\mathcal{C}_{local}$）。长度保真度（*LF*）计算生成轨迹长度与真实轨迹长度的比值，用于量化模型在不走捷径或生成冗余运动的情况下复现专家几何尺度的能力。

- 运动学连贯性：平均加加速度（$\mathcal{J}$）通过计算位置三阶导数的平均幅值来评估轨迹的平滑度。数值越低，表示运动越平滑、越可跟踪，也反映出全局拓扑一致性（$\mathcal{C}_{global}$）。

- 生成可行性：推理成功率（*ISR*）表示生成器生成无碰撞路径并在时域内收敛到目标区域（误差 $< 0.5m$）的回合所占的百分比。预测碰撞率（*PCR*）衡量生成的轨迹与输入点云中的障碍点相交的比例 $\mathcal{O}_{lo}$。推理延迟记录单次生成步骤的平均实际运行时间。

B. 定量分析

定量结果（表 I）从实证角度验证了所提出的“架构即正则化”范式，并揭示了现有基线方法在协调保真度与平滑度之间权衡方面的局限性。

1）保真度—平滑度困境分析：基线方法表现出明显的两极分化，证实了几何约束与运动学约束之间存在冲突：

- 高保真度、低平滑度（CAVE）：CAVE 实现了出色的几何保真度，最终位移误差（FDE）较低（0.041m），但这种精度是以严重的运动学不稳定性为代价的，加加速度高达惊人的 527.87 m/s^3，足以证明这一点。这种不规则的高频振荡使生成的轨迹实际上无法被下游控制器跟踪。

- 高平滑度、低保真度（DTG）：相较之下，基于扩散的 DTG 生成的轨迹最平滑（22.49 m/s^3），但存在显著的终端漂移（FDE 为 0.699m）和较高的预测碰撞率（32.47%）。这验证了我们的假设：静态条件无法提供终止状态收敛所需的细粒度引导。

- 表现欠佳的基线方法（S2TNet 和 BC）：标准模仿方法难以掌握任一目标，生成的轨迹位移误差较大（> 0.7m），运动学连贯性也较差。

2）通过 *DRIFT* 化解冲突：DRIFT 通过在结构上将全局推理与局部推理解耦，有效化解了这一两难局面。它实现了厘米级终端保真度（0.041m 最终位移误差），可媲美以精度为重点的 CAVE，同时保持了具有竞争力的运动学平滑度（27.19 m/s^3），与以平滑度为重点的 DTG 不相上下。至关重要的是，这种平衡带来了较高的推理成功率（91.66%）和较低的预测碰撞率

表 I：轨迹生成性能的定量评估

方法	ISR (%)	PCR (%)	长度保真度 (%)	最终位移误差 (m)	加加速度 (m/s³)	延迟 (s)
BC [44]	0.52	5.55	90.61	1.44	118.37	**0.05**
CAVE [38]	**96.80**	**4.73**	99.72	**0.041**	527.87	0.09
S2TNet [43]	2.35	5.32	**99.73**	0.712	163.19	0.08
DTG [18]	45.35	32.47	99.20	0.699	**22.49**	0.14
DRIFT（我们的方法）	91.66	5.17	99.73	**0.041**	27.19	0.27
不使用图神经网络	87.45	5.40	99.71	0.058	22.17	0.30
不含 GTGRU（U-Net）	92.03	5.47	99.70	0.043	27.84	2.10
不含注意力	64.04	5.51	99.82	0.094	24.05	0.29

注：***ISR***：推理成功率，***PCR***：预测碰撞率，长度保真度：长度保真度（与真实轨迹长度之比）。*DRIFT* 在几何精度（最终位移误差）和运动学平滑性（加加速度）之间实现了最佳平衡。

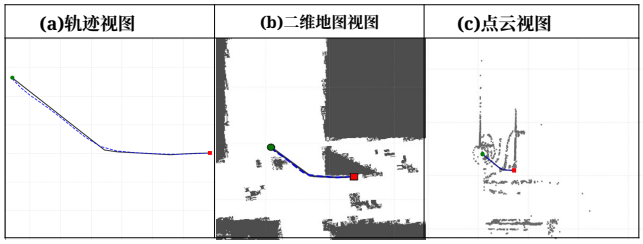

图 5：预测轨迹（深色）与真实轨迹（浅灰色）在 (a) 轨迹、(b) 二维地图和 (c) 点云视图中均高度吻合，表明 DRIFT 兼顾了精度与平滑性。

（5.17%）。这些结果展现了 DRIFT 独特的能力：生成既几何精确（适用于细粒度任务）又运动学连贯（可稳定执行）的参考规划，满足高保真轨迹生成的核心要求。

C. 消融分析：归纳偏置

为验证所提出架构偏置的作用，我们分析了表 I 中所示的变体。

1）关系归纳偏置的影响（无 *GNN*）：用标准 U-Net 编码器替换 SSP 模块后，ISR 下降了 4.2%。性能下降表明，基于网格的卷积难以捕捉无结构点云的非局部拓扑连通性，而这对于在复杂环境中求解全局几何约束至关重要。

2）时间注意力偏置的影响（无注意力）：移除动态注意力机制（GTGRU）会导致性能灾难性下降，ISR 降至 64.04%，最终位移误差则显著恶化至 0.094 米。这一实证结果验证了静态条件化不足以胜任细粒度任务的假设。在去噪过程中，逐步注意力机制对于纠正累积误差不可或缺，从而确保终端状态保真度。

VI. 结论

在本文中，我们提出了 DRIFT，这是一种条件生成框架，能够有效平衡无地图轨迹生成中的几何精度与运动学平滑性。通过采用“架构即正则化”范式，我们融入了关系与时间归纳偏置，将全局拓扑推理与细粒度终端细化解耦。定量实验表明，DRIFT 在保持具有竞争力的平滑性的同时，实现了厘米级的模仿保真度，在生成可执行参考规划方面优于现有基线方法。未来工作将着重于借助一致性模型加速推理，并将生成器与闭环跟踪控制器集成，以支持动态真实世界部署。

致谢

这应是一段位于参考文献之前的简单段落，用以感谢那些支持您撰写本文的个人和机构。

参考文献

[1] S. M. LaValle，《规划算法》。剑桥大学出版社，2006。[2] S. Thrun，“概率机器人学”，《*ACM* 通讯》，第 45 卷，第 3 期，第 52–57 页，2002。[3] J. Liang、P. Gao、X. Xiao、A. J. Sathyamoorthy、M. Elnoor、M. C. Lin 和 D. Manocha，“Mtg：用于室外导航、具备可通行性覆盖能力的无地图轨迹生成器”，载于*2024* 年 *IEEE* 国际机器人与自动化会议 *(ICRA)*。IEEE，2024，第 2396–2402 页。[4] Y. Hu、S. Wang、Y. Xie、S. Zheng、P. Shi、I. Rudas 和 X. Cheng，“基于深度强化学习的未知环境移动机器人无地图导航及其局部最优问题”，*IEEE*机器人与自动化快报，第 10 卷，第 1 期，第 628–635 页，2025。[5] T. Ort、L. Paull 和 D. Rus，“无需详细先验地图的乡村环境自动驾驶车辆导航”，载于*2018*年 *IEEE* 国际机器人与自动化会议 *(ICRA)*，2018，第 2040–2047 页。[6] Y. Zhu、R. Mottaghi、E. Kolve、J. J. Lim、A. Gupta、L. Fei-Fei 和 A. Farhadi，“利用深度强化学习在室内场景中实现目标驱动视觉导航”，载于*2017* 年 *IEEE* 国际机器人与自动化会议 *(ICRA)*，2017，第 3357–3364 页。[7] P. Mirowski、R. Pascanu、F. Viola、H. Soyer、A. J. Ballard、A. Banino、M. Denil、R. Goroshin、L. Sifre、K. Kavukcuoglu、D. Kumaran 和 R. Hadsell，“学习在复杂环境中导航”，2017。

[8] [ ] 1611 03673 在线。可访问：https://arxiv.org/abs/。C. Mavrogiannis、F. Baldini、A. Wang、D. Zhao、P. Trautman、A. Steinfeld 和 J. Oh，“社交机器人导航的核心挑战：综述”，《*ACM* 人机交互汇刊》，第 12 卷，第 3 期，第 1–39 页，2023。[9] T. Kruse、A. K. Pandey、R. Alami 和 A. Kirsch，“具备人类感知能力的机器人导航：综述”，《机器人与自主系统》，第 61 卷，第 12 期，第 1726–1743 页，2013。[10] N. Hirose、D. Shah、A. Sridhar 和 S. Levine，“Sacson：面向社交导航的可扩展自主控制”，*IEEE*机器人与自动化快报，第 9 卷，第 1 期，第 49–56 页，2024。[11] Y. Gao 和 C.-M. Huang，“具备社交感知能力的机器人导航评估”，《机器人与人工智能前沿》，第 8 卷，第 721317 页，2022。[12] P. E. Hart、N. J. Nilsson 和 B. Raphael，“最小代价路径启发式确定的形式基础”，《*IEEE* 系统科学与控制论汇刊》，第 4 卷，第 2 期，第 100–107 页，1968。

[13]S. Karaman 和 E. Frazzoli，“最优运动规划的基于采样的算法”，《国际机器人研究期刊》，第 30 卷，第 7 期，第 846–894 页，2011。 [在线]。可访问：https://doi.org/ 10 1177 0278364911406761 。/ Z. Han、L. Xu、L. Pei 和 F. Gao，“通过优化嵌入网络生成适用于自主飞行的动态可行轨迹”，IEEE机器人与自动化快报，第 10 卷，10 002，2025 10，第 9995 页–。[15] M. Janner、Y. Du、J. B. Tenenbaum 和 S. Levine，“利用扩散进行灵活行为合成的规划”，2022。 [在线]。可访问：https://arxiv.org/abs/ 2205 09991 。C. Chi、Z. Xu、S. Feng、E. Cousineau、Y. Du、B. Burchfiel、R. Tedrake 和 S. Song，“扩散策略：通过动作扩散进行视觉运动策略学习”，《国际机器人研究期刊》，第 0 卷，第 0 期，第 02783649241273668 页，0。 [在线]。可访问：https://doi.org/ 10 1177 02783649241273668 。/ A. Sridhar、D. Shah、C. Glossop 和 S. Levine，“Nomad：用于导航与探索的目标掩码扩散策略”，载于 2024 年 IEEE 国际机器人与自动化会议 (ICRA)。IEEE，2024，第 63–70 页。[18] J. Liang、A. Payandeh、D. Song、X. Xiao 和 D. Manocha，“DTG：用于无地图全局导航的基于扩散的轨迹生成”，载于 2024 年 IEEE/RSJ 智能机器人与系统国际会议 (IROS)，2024，第 5340–5347 页。[19] J. Ho、A. Jain 和 P. Abbeel，“去噪扩散概率模型”，载于《神经信息处理系统进展》，H. Larochelle、M. Ranzato、R. Hadsell、M. Balcan 和 H. Lin 编，第 33 卷。Curran Associates, Inc.，2020，第 6840–6851 页。[在线]。可访问：https://proceedings.neurips.cc/paper files/paper/ 2020/file/4c5bcfec8584af0d967f1ab10179ca4b-Paper.pdf [20] C. R. Qi、L. Yi、H. Su 和 L. J. Guibas，“Pointnet++：在度量空间中的点集上进行深层次特征学习”，载于《神经信息处理系统进展》，I. Guyon、U. V. Luxburg、S. Bengio、H. Wallach、R. Fergus、S. Vishwanathan 和 R. Garnett 编，第 30 卷。Curran Associates, Inc.，2017。[在线]。可访问：https://proceedings.neurips.cc/paper files/paper/ 2017/file/d8bf84be3800d12f74d8b05e9b89836f-Paper.pdf [21] Y. Wang、Y. Sun、Z. Liu、S. E. Sarma、M. M. Bronstein 和 J. M. Solomon，“用于点云学习的动态图卷积神经网络”，ACM Trans. Graph.，第 38 卷，第 5 期，2019 年 10 月。 [在线]。可访问：https://doi.org/ 10 1145 3326362 。/ B.-S. Hua、M.-K. Tran 和 S.-K. Yeung，“逐点卷积神经网络”，载于 IEEE计算机视觉与模式识别会议 (CVPR) 论文集，2018 年 6 月。[23] A. Rosinol、A. Gupta、M. Abate、J. Shi 和 L. Carlone，“三维动态场景图：结合地点、物体和人类的可操作空间感知”，arXiv 预印本 arXiv:2002.06289，2020。[24] L. Chen、Z. He、L. Wang、C. Liu 和 Q. Chen，“面向物体导航的时序场景—物体图学习”，IEEE机器人与自动化快报，第 10 卷，第 5 期，第 4914–4921 页，2025。[25] Y. Meng、C. Guo、A. Li 和 Y. Luo，“用于陌生环境物体目标导航的上下文感知图推理与生成对抗模仿学习”，IEEE机器人与自动化快报，第 10 卷，第 4 期，第 3803–3810 页，2025。[26] A. Sanchez-Gonzalez、N. Heess、J. T. Springenberg、J. Merel、M. Riedmiller、R. Hadsell 和 P. Battaglia，“作为可学习物理引擎、用于推理与控制的图网络”，载于第 35 届国际机器学习会议论文集，丛书《机器学习研究论文集》，J. Dy 和 A. Krause 编，第 80 卷。PMLR，2018 年 7 月 10–15 日，第 4470–4479 页。 [在线]。可访问：https://proceedings.mlr.press/v80/sanchez-gonzalez18a.html [27] Q. Wu、X. Gong、K. Xu、D. Manocha、J. Dong 和 J. Wang，“通过生成式模仿学习实现室内场景中的目标驱动视觉导航”，IEEE机器人与自动化快报，第 6 卷，第 1 期，第 175–182 页，2021。[28] C. Chen 、 Y. Liu 、 S. Kreiss 和 A. Alahi，“人群—机器人交互：基于注意力的深度强化学习实现人群感知机器人导航”，载于 2019 年机器人与自动化国际会议 (ICRA)。IEEE，2019，第 6015–6022 页。[29] Y. Yang、J. Jiang、J. Zhang、J. Huang 和 M. Gao，“St²：用于人群感知自主导航的时空状态转换器”，IEEE机器人与自动化快报，第 8 卷，第 2 期，第 912–919 页，2023。[30] K. D. Katyal、G. D. Hager 和 C.-M. Huang，“ 面向自适应人群导航的意图感知行人预测 ”，载于 2020 年 IEEE 国际机器人与自动化会议 (ICRA)，2020，第 3277–3283 页。[31] A. Vaswani、N. Shazeer、N. Parmar、J. Uszkoreit、L. Jones、A. N. Gomez、L. u. Kaiser 和 I. Polosukhin，“注意力机制即一切所需”，发表于神经信息处理系统进展，I. Guyon、U. V. Luxburg、S. Bengio、H. Wallach、R. Fergus、S. Vishwanathan 和 R. Garnett 编，第30卷。Curran Associates, Inc.，2017 年。[在线]。网址：https://proceedings.neurips.cc/paper files/paper/ 2017/file/3f5ee243547dee91fbd053c1c4a845aa-Paper.pdf [32] M. Adamkiewicz、T. Chen、A. Caccavale、R. Gardner、P. Culbertson、J. Bohg 和 M. Schwager，“神经辐射世界中的纯视觉机器人导航”，*IEEE*机器人与自动化快报，第7卷，第2期，第4606–4613页，2022年。[33] B. Mildenhall、P. P. Srinivasan、M. Tancik、J. T. Barron、R. Ramamoorthi 和 R. Ng，“NeRF：用于视图合成的神经辐射场场景表示”，《*ACM* 通讯》，第65卷，第1期，第99–106页，2021年12月。 [ ] 10 1145 3503250 在线。网址：https://doi.org/ 。/ [34] M. Cordts 、 M. Omran 、 S. Ramos 、 T. Rehfeld 、 M. Enzweiler 、 R. Benenson、U. Franke、S. Roth 和 B. Schiele，“用于城市场景语义理解的 Cityscapes 数据集”，发表于*IEEE*计算机视觉与模式识别会议（*CVPR*）论文集，2016年6月。[35] L.-C. Chen、Y. Zhu、G. Papandreou、F. Schroff 和 H. Adam，“用于语义图像分割的编码器-解码器与空洞可分离卷积”，发表于欧洲计算机视觉会议（*ECCV*）论文集，2018年9月。[36] P. W. Battaglia、J. B. Hamrick、V. Bapst、A. Sanchez-Gonzalez、V. Zam-baldi、M. Malinowski、A. Tacchetti、D. Raposo、A. Santoro、R. Faulkner、C. Gulcehre、F. Song、A. Ballard、J. Gilmer、G. Dahl、A. Vaswani、K. Allen、C. Nash、V. Langston、C. Dyer、N. Heess、D. Wierstra、P. Kohli、M. Botvinick、O. Vinyals、Y. Li 和 R. Pascanu，“关系归纳偏置、深度学习与图网络”，2018年。[37] Y. Liu、T. Yuan、Y. Wang、Y. Wang 和 H. Zhao，“VectorMapNet：端到端矢量化高清地图学习”，发表于第*40*届国际机器学习会议论文集，《机器学习研究论文集》系列，A. Krause、E. Brunskill、K. Cho、B. Engelhardt、S. Sabato 和 J. Scarlett 编，第202卷。PMLR，2023年7月23日至29日，第22 352–22 369页。[在线]。网址：https://proceedings.mlr.press/v202/liu23ax.html [38] K. Sohn、H. Lee 和 X. Yan，“使用深度条件生成模型学习结构化输出表示”，发表于神经信息处理系统进展，C. Cortes、N. Lawrence、D. Lee、M. Sugiyama 和 R. Garnett 编，第28卷。Curran Associates, Inc.，2015年。 [在线]。网址：https://proceedings.neurips.cc/paper files/paper/2015/file/8d55a249e6baa5c06772297520da2051-Paper.pdf [39] I. Goodfellow、J. Pouget-Abadie、M. Mirza、B. Xu、D. Warde-Farley、S. Ozair、A. Courville 和 Y. Bengio，“生成对抗网络”，《*ACM* 通讯》，第63卷，第11期，第139–144页，2020年。[40] A. Gupta、J. Johnson、L. Fei-Fei、S. Savarese 和 A. Alahi，“社会生成对抗网络：利用生成对抗网络生成社会可接受轨迹”，发表于*IEEE*计算机视觉与模式识别会议（*CVPR*）论文集，2018年6月。[41] A. Ghafourian、Z. CuiZhu、D. Shi、I. Chuang、F. Charette、R. Sachdeva 和 I. Soltani，“通过少样本航点检测实现分层端到端自主导航”，*IEEE*机器人与自动化快报，第9卷，第4期，第3211–3218页，2024年。[42] W. Feng、L. Ding、R. Zhou、C. Xu、H. Yang、H. Gao、G. Liu 和 Z. Deng，“面向行星探测车、考虑非几何危险的基于学习的端到端导航”，*IEEE*机器人与自动化快报，第8卷，第7期，第4084–4091页，2023年。[43] W. Chen、F. Wang 和 H. Sun，“S2TNet：用于自动驾驶轨迹预测的时空变换器网络”，发表于第*13*届亚洲机器学习会议论文集，《机器学习研究论文集》系列，V. N. Balasubramanian 和 I. Tsang 编，第157卷。PMLR，2021年11月17日至19日，第454–469页。 [在线]。网址：https://proceedings.mlr.press/v157/chen21a.html [44] D. J. Foster、A. Block 和 D. Misra，“行为克隆是否就是你所需的一切？理解模仿学习中的时域”，发表于神经信息处理系统进展，A. Globerson、L. Mackey、D. Belgrave、A. Fan、U. Paquet、J. Tomczak 和 C. Zhang 编，第37卷。Curran Associates, Inc.，2024年，第120 602–120 666页。[在线]。网址：https://proceedings.neurips.cc/paper files/paper/ 2024/file/da84e39ae51fd26bb5110d9659c06e13-Paper-Conference.pdf [45] H. Kretzschmar、M. Spies、C. Sprunk 和 W. Burgard，“通过逆强化学习实现符合社会规范的移动机器人导航”，国际机器人研究期刊，第35卷，第11期，第1289–1307页，2016年。 [在线]。网址：https://doi.org/10.1177/ 0278364915619772