arXiv:2305.04352v1 [cs.RO] 7 May 2023

我们需要谈谈：识别并克服对通信至关重要的自动驾驶场景

Nathaniel Moore Glaser 和 Zsolt Kira，佐治亚理工学院{nglaser,zkira}@gatech.edu

摘要——**本文探讨网联自动驾驶车辆的无碰撞轨迹规划任务。我们特别关注通信至关重要的 情境——在这些情境中，单智能体系统存在盲区，需要多智能体协作。为识别此类情境，我们提出一种方法，该方法：(1) 基于真实自动驾驶数据集模拟多智能体视角；(2) 找出对孤立智能体而言具有挑战性的场景；(3) 通过对抗性遮挡增强场景。为克服 这些挑战，我们提出将基于代价地图的轨迹评估扩展到分布式多智能体环境。实验表明，与单智能体基线方法相比，我们的带宽高效、具备不确定性感知能力的 方法可将碰撞率降低多达62.5%** 。

I. 引言

单智能体系统容易受到感知退化的影响，例如图1所示的视线遮挡。这类退化十分危险，可能会误导下游规划流程。它们也极为罕见却危险，存在于“长尾”情境中，而现代基于学习的算法历来难以应对这类情境。本文探讨多智能体 协作如何为这些罕见但危险的情境提供一种“保障”。

具体而言，我们研究联网自动驾驶车辆的通信关键轨迹规划问题。在这一场景中，多机器人通信对于降低车辆碰撞率至关重要。

首先，我们使用轻量级数据集封装器来识别这些场景，该封装器接收来自开源数据集 [5] 的轨迹记录并合成激光雷达扫描数据。我们演示了模拟和识别有趣的多智能体场景，以及增强不太有趣场景的能力。

其次，我们通过一种用于执行分布式轨迹评分的新颖方法克服了这些挑战性场景。我们的方法使基于代价地图的规划器能够高效查询协作方的推断结果。与单智能体基线相比，我们的方法最多可将严重碰撞减少62.5%。我们展示了处理流程中若干关键组件的优势，其中包括 (1) 一个

可学习的运动预测模块，用于预测未来的占用情况和感知不确定性；（2）带宽高效的通信器选择机制；以及（3）用于多智能体分数融合的不确定性感知机制。

相关工作。 先前的协同感知工作（如 V2X-Sim [3]，）采用多智能体协作来应对推断结果失败的问题。然而，这些失败往往对短期规划影响有限，尤其是对于距离较远的

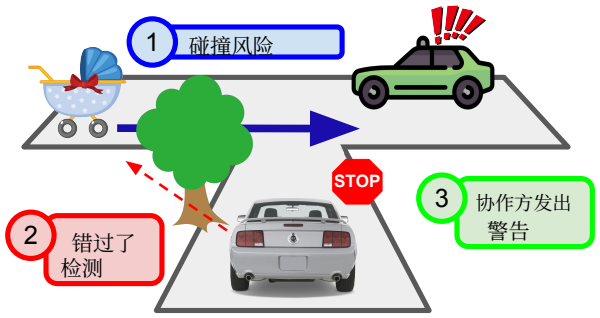

图 1：通信关键**规划**。在某些情况下，协作对于避免不佳的规划决策至关重要。

推断结果。为此，我们的工作旨在寻找那些同样会影响规划的协同感知场景子集。为了应对这些场景，我们借鉴了运动预测 和基于代价地图的规划方面的先前工作。与 Khurana等人 [2], 类似，我们采用学习式处理流程，根据俯视激光雷达栅格图预测场景占用，并同样基于这些占用预测结果进行轨迹评分。然而，与他们的工作不同，我们将这种单智能体 范式扩展为分布式多智能体 范式，并在此过程中利用高效通信 [1]。

二、方法

A. 识别通信关键场景

本节提出一种方法，用于模拟、识别和增强 对网联自动驾驶车辆而言有趣的场景。我们的方法解决了真实世界自动驾驶汽车数据集面临的两大关键挑战：

1）**单视角**。大多数现有的 SDV 数据集都是从单智能体 视角采集的，因此无法自然地支持多机器人协作。为弥补真实多机器人 SDV 数据的缺乏，我们使用轻量级模拟器，在共享场景中合成任意数量参与体的局部视角。

2) **罕见但危险**。对于自动驾驶车辆（SDV）而言，大多数场景都很简单，可通过单智能体算法加以解决。然而，少数场景会造成严重后果（例如漏检）；我们希望评估系统在这些关键情境中的性能。为弥补常见但简单的场景与罕见但危险的场景之间的不平衡，我们提出筛选真实数据，找出为保障安全而需要通信的情境。

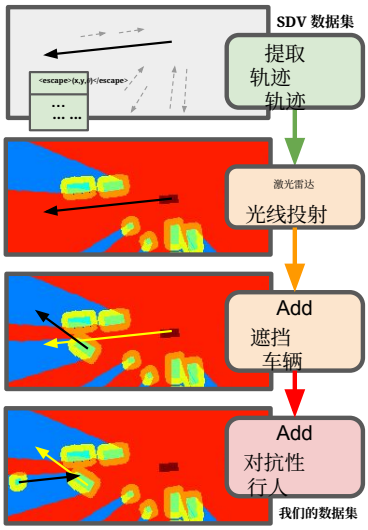

图 2：**对抗性增强**。使用激光雷达光线投射渲染种子数据集中的轨迹，并通过加入遮挡车辆和对抗性行人进行增强。

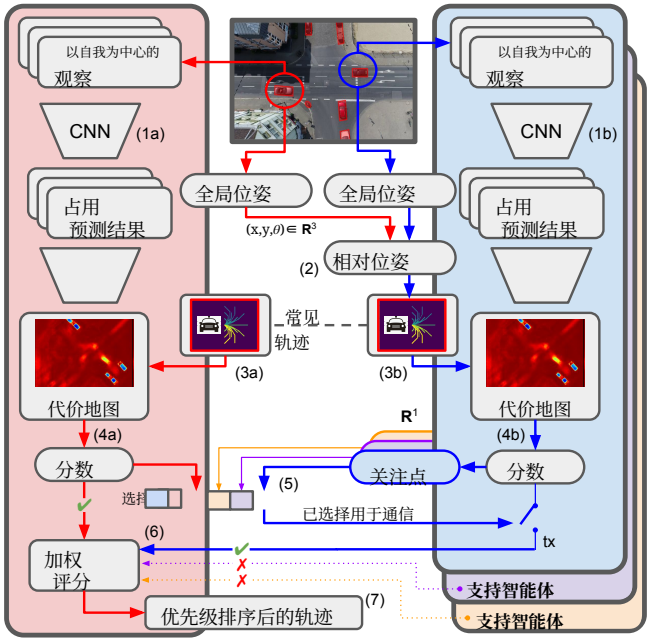

图 3：**分布式轨迹评估**。目标智能体（左侧：红色）利用协作方（右侧：蓝色、紫色、黄色）的推断结果，为一组轨迹候选项打分。

模拟。为模拟多机器人传感器信息，我们采用了先前工作 [1]中的**协作鸟瞰图模拟器**（CoBEV-Sim）。这个轻量级数据集封装器会读取从俯视数据集中采集的运动轨迹 [5]，并为其中任意车辆子集合成局部感知信息（即激光雷达扫描数据）。

识别。我们将来自 **Interaction** 数据集 [5] 的轨迹插入 **CoBEV-Sim** 封装器，以识别通信关键场景。我们将该数据集细分为若干“场景”，每个场景由 3 秒的观测窗口和 1 秒的规划窗口组成。接下来，我们随机选择一组车辆，使其具备通信能力，并为每辆车生成一组合理的未来轨迹候选项。最后，我们查询 **CoBEV-Sim** 封装器，找出在观测窗口期间不可见、但在规划窗口期间与这些轨迹候选项发生碰撞的智能体。这些碰撞源于有限的单智能体感知能力；此类情况虽然罕见却十分危险，而协同感知很可能会从这些场景中获益最大。

增强。鉴于危险场景较为罕见，我们通过引入（1）对抗性遮挡物和（2）对抗性行人来增强其余场景，具体总结见图 2。我们生成遮挡智能体时，使其从一个具备通信能力的智能体前方穿过，从而遮挡其传感器。我们生成对抗性行人时，使其在观测窗口期间沿该遮挡物的“阴影”移动，并在规划窗口期间与该智能体的行进路径相交。

B. 克服通信关键场景

在本节中，我们提出一种方法，以克服上一节所识别情境带来的感知对抗性。具体而言，如图3所示，我们的方法使基于代价地图的规划器能够利用分布式推断结果。

运动预测。首先，每个智能体都使用卷积神经网络 $\boldsymbol{\Phi}$ 将一系列对齐的二维鸟瞰图（鸟瞰图）观测 $\boldsymbol{X}^{T^-:0}$ 转换为一系列二维运动预测结果：

$$\boldsymbol{P}_C^{1:T^+} = \boldsymbol{\Phi}(\boldsymbol{X}^{T^-:0}) \tag{1}$$

$$C = \{\textbf{empty}, \textbf{occupied}, \textbf{shadow}, \textbf{outOfRange}\} \tag{2}$$

其中 $\boldsymbol{P}^{1:T^+}_{:C}$ 表示经过 Softmax 归一化的时间置信度图。这些置信度图通过交叉熵损失与真实标注的未来鸟瞰图观测进行训练。按通道进行 argmax 运算可得到语义掩码：

$$\boldsymbol{M}^{1:T^+} = \arg\max_C \boldsymbol{P}^{1:T^+} \tag{3}$$

注意，每个智能体除了预测未来占用状态（使用**占用**类别）外，还会预测感知不确定性（使用**阴影**类别）。这些输出使每个智能体能够说明其对预测何时存在不确定性，从而让有信心的智能体能够在不确定的智能体之上坚持自己的判断。

代价地图生成。接下来，每个智能体将其二维语义预测结果转换为代价地图（图 3.1）。具体而言，每个智能体仅针对 **占用** 类，根据二值掩码序列计算有符号距离场（**有符号距离场**）[4]：

$$\boldsymbol{D}^t = \textbf{SDF}(\boldsymbol{M}^t) \text{ where } \boldsymbol{M} = \textbf{occupied} \tag{4}$$

轨迹生成。每个智能体都维护一组相同的 N 局部轨迹候选项 $\mathbb{S} = \{S_i\}^N$，其中每个轨迹候选项都定义了未来时间步 $S_i = \{(x_t,\ y_t,\ \theta_t)\}_1^{T^+}$ 中智能体位置和航向的序列。这些轨迹的生成旨在覆盖广泛的可行车辆机动，具体范围由线性和角加速度限制决定（图 3.3）。

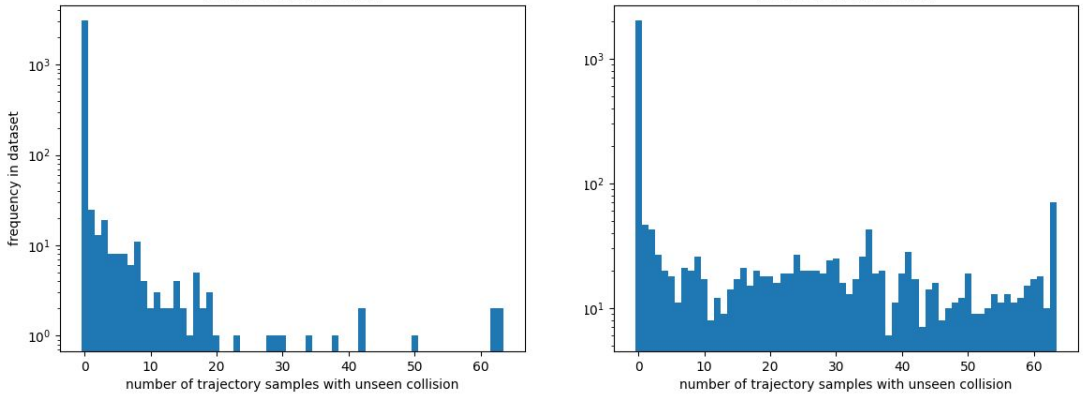

图 4：**对抗性增强前后通信关键场景的出现频率**。对于每个数据集场景，我们统计了与未见过的道路参与者发生碰撞的轨迹候选项数量（总数为 $N = 64$）。存在更多碰撞轨迹候选项的数据集较为罕见，但这类数据集场景中发生的危险事件可以通过与协作方协作来避免，从而防止做出危险的规划决策。左侧展示**Interaction** 数据集的结果，右侧展示其对抗性增强后的结果，数值均采用对数刻度。

分布式代价地图提取。本节介绍如何从支持智能体 a 提取轨迹候选项 i的代价地图值。首先，每个支持智能体都会接收广播的目标位姿，并将其静态局部轨迹集转换到目标智能体所在的位置（图 3.2）：

$$S^t_{a,i} = R^e_a S^t_{e,i} \tag{5}$$

其中， R^e_a 表示自我中心智能体 e 与支持智能体 a之间的相对位姿变换。

接下来，每个智能体从**有符号距离场**（$\boldsymbol{D}^t$）中提取轨迹航点（S^t）处的值，以计算轨迹评分（图 3.4）：

$$C^t = \boldsymbol{D}^t[S^t]_{\min} \tag{6}$$

其中， $[\cdot]_{\{\max,\min,\text{avg}\}}$ 表示在特定轨迹位姿处提取代价地图的策略。在本工作中，我们将车辆占用区域投影到指定位姿上，并计算该占用区域下所有像素的最大值（**最大值**）、最小值（**最小值**）或平均值（**平均值**）。

此外，为了辅助不确定性感知融合，每个智能体会从其预测结果中提取若干其他量：

$$f_o = \max_t (\boldsymbol{M}^t[S^t]_{\text{avg}}) \text{ where } \boldsymbol{M} = \textbf{occupied} \tag{7}$$

$$p_o = \sum_t \boldsymbol{P}^t_C[S^t]_{\text{avg}} \text{ where } C = \textbf{occupied} \tag{8}$$

$$f_s = \sum_t (\boldsymbol{M}^t[S^t]_{\text{avg}}) \text{ where } \boldsymbol{M} = \textbf{shadow} \tag{9}$$

$$p_s = \sum_t \boldsymbol{P}^t_C[S^t]_{\text{avg}} \text{ where } C = \textbf{shadow} \tag{10}$$

带宽高效的**智能体选择**。为避免通信信道饱和，每个支持智能体都会计算一个标量值，以反映其对自车智能体轨迹规划的“关注程度”（图 3.5）：

$$w = \sum_i p^i_o \tag{11}$$

其中， p^i_o 指轨迹 i中**占用**类别的累计置信度。接下来，自我中心智能体会比较自身与支持智能体的分数，以确定需要进一步通信的候选对象：

$$\overline{a} = \arg\max_{a \in \text{all}} w_a \tag{12}$$

分数融合（朴素）。此时，每个智能体都已计算出每个轨迹候选项（i）在每个时间戳（t）上的分数。这些分数可以（朴素地）合并，从而为每条轨迹生成一个分数：

$$F^{\text{all}}_i = \sum_{a \in \text{all}} \min_t C^t_{a,i} \tag{13}$$

分数融合（选择性）。为了节省带宽，我们首先提议与“最关注”的智能体通信：

$$F^{\text{concern}}_i = \sum_{a \in \{\text{ego},\overline{a}\}} \min_t C^t_{a,i} \tag{14}$$

分数融合（不确定性感知）。为使置信度较高的智能体能够凌驾于置信度较低的智能体之上，我们进一步提出不确定性加权融合（图3.6）：

$$F_i = \sum_{a \in \{\text{ego},\overline{a}\}} u_{a,i} \min_t C^t_{a,i} \tag{15}$$

$$u = \frac{(1+f_o)(1+p_o)}{(1+f_s)(1+p_s)} \tag{16}$$

其中，不确定性加权项（u）与占用（f_o，p_o）成正比，与感知不确定性（f_s，p_s）成反比。该项会为预测将发生碰撞的轨迹（即基于其与**占用**二值掩码和置信度图的重叠情况）赋予更高权重，并降低具有显著感知不确定性的轨迹（即基于其与**阴影**类别的重叠情况）的权重。

轨迹优先级排序。最后，根据融合评分对轨迹集合进行排序（图 3.7）：

$$\mathbb{S}_{\text{prioritized}} = [S_i | \forall i \in \arg\operatorname*{sort}_i F_i] \tag{17}$$

	方法	可用 N_{com}	Top-k 碰撞率（%） $k=1$	（相对于自我）	$k=10$	（相对于自我）	平均数量 通信链接
基线方法	ego	0	5.8	100	14.3	100	0.000
	随机轨迹	0	48.6	837	52.2	365.5	0.000
	rand	1	8.0	137	22.3	156.3	0.783
	自我 + 全部	3	4.3	75.0	14.0	98.0	2.862
真实标注视觉	ego*	0	1.4	25.0	12.5	87.8	0.000
贡献 A: （与关注者进行通信）	自我 + 关注点	1	4.3	75.0	8.7	60.9	0.754
		2	**3.6**	**62.5**	**7.8**	**54.8**	1.348
		3	4.3	75.0	11.0	77.2	2.080
贡献 A+B: （与不确定性融合）	自我 + 关注点	1	3.6	62.5	7.8	54.8	0.754
		2	2.9	50.0	6.6	46.2	1.348
		3	**2.2**	**37.5**	**5.5**	**38.6**	2.080

表 I：**最高k 碰撞率（ n智能体间通信）**。此表展示了我们的方法与基线方法的碰撞率对比。“（相对于自我）”列显示了与单智能体（第一行）相比，碰撞率的百分比变化。

III. 结果

我们通过分析碰撞率来评估性能。为**识别**通信关键场景，我们计算轨迹候选项与未见障碍物发生碰撞的比率。为**克服**这些具有挑战性的场景，我们展示了一种带宽高效的不确定性感知分布式多智能体轨迹评分方法如何降低碰撞率。

A. 识别通信关键场景

如图 4 所示，在 x =0 处的大型垂直条形图表明，大多数自动驾驶车辆场景都具有足够的单智能体感知信息，可用于安全规划。在这些图中，$x=0$ 表示没有任何轨迹候选方案存在与未被观察到的参与体发生碰撞的风险。然而，如 $x>0$ 处的条形图所示，仍有少数（但数量可观的）场景涉及这样的规划：单智能体感知无法察觉某些潜在碰撞。

为使算法更好地应对这些罕见事件，我们通过对抗性放置的场景参与体扩充了数据集。正如左右图之间 $x>0$ 处质量的增加所示，这些扩充增加了适用于多机器人规划的有意义场景数量。

B. 应对通信关键场景

如表 I 所示，与单智能体和多智能体基线方法相比，我们的方法显著降低了碰撞率；其性能也接近拥有全知的完美视觉的自我中心智能体。我们还证明，我们的方法还有一个额外优势：选择，即可以从排名前 10 的候选方案（$k=10$）中选取一条轨迹，而性能仅略有下降。此外，我们指出，带宽高效的通信方选择机制（贡献 A）与不确定性感知的多智能体分数融合（贡献 B）相结合，可将碰撞率降低至自我中心智能体的 37.5%，同时还减少了不同可用通信方数量（N_{com}）下所需的通信连接数：$1\rightarrow 0.75$、$2\rightarrow 1.35$、$3\rightarrow 2.08$。

IV. 致谢

本研究由美国海军研究办公室资助，资助编号为 N00014-18-1-2829。

V. 结论

在本研究中，我们提出了一种**识别** 并**克服** 通信关键场景的方法。我们证明，我们能够：(1) 从单智能体数据集中模拟 多智能体视角；(2)识别 适合开展多智能体协作的场景；(3) 增强不那么有趣的场景——所有这些都是为了更好地测试协同感知与规划算法。此外，我们还证明，在这些具有挑战性的情境中，我们的带宽高效、不确定性感知方法可将碰撞率降至单智能体表现的 37。5 %。

未来工作。未来工作将探讨考虑更贴近现实的多智能体组件所带来的挑战，例如噪声传感器、不精确的位姿估计以及通信延迟。

参考文献

[1]Nathaniel Moore Glaser 和 Zsolt Kira。“通过多智能体轨迹交换实现通信关键型规划”。载于：*arXiv* 预印本 *arXiv:2303.06080* （2023）。[2] Tarasha Khurana 等人。“用于自监督占用预测的可微光线投射”。载于：计算机视觉—*ECCV 2022*：第 *17* 届欧洲计算机视觉会议，特拉维夫，以色列，*2022* 年 *10* 月 *23—27* 日，论文集，第 *XXXVIII* 部分。施普林格。2022 年，第 353–369 页。[3] Yiming Li 等人。“V2X-Sim：自动驾驶多智能体协同感知数据集与基准”。载于：*IEEE* 《机器人与自动化快报》7.4（2022 年），第 10914–10921 页。DOI：10.1109/LRA. 2022.3192802。[4] Helen Oleynikova 等人。“有符号距离场：兼用于建图与规划的自然表示”。载于：*RSS 2016*研讨会：几何及其他——机器人学的表示、物理与场景理解。密歇根大学。2016 年。[5] Wei Zhan 等人。“Interaction 数据集：交互式驾驶场景中的国际对抗与协作运动数据集及语义地图”。载于：*arXiv* 预印本 *arXiv:1910.03088* （2019 年）。