

DOI:10.19651/j.cnki.emt.2211870

# 基于生成对抗网络的自动驾驶交通场景生成<sup>\*</sup>

景荣荣<sup>1</sup> 吴 兰<sup>2</sup> 张坤鹏<sup>1,3</sup>(1. 河南工业大学电气工程学院 郑州 450001; 2. 河南工业大学机电工程学院 郑州 450001;  
3. 清华大学自动化系 北京 100084)

**摘要:** 自动驾驶汽车是智能交通的重要组成部分,也是未来交通的发展趋势。提高自动驾驶技术的可靠性需要对自动驾驶汽车进行广泛的测试。然而,进行实车路测成本高昂且风险较高。如何建立模型生成多样且真实的交通场景,在测试自动驾驶技术的时候显得尤为重要。针对自动驾驶交通场景生成问题,提出了一个基于生成对抗网络的交通场景生成模型 TSG-GAN。TSG-GAN 模型利用丰富的交通场景数据(如车道的几何形状、人行横道、交通信号、周围车辆等)快速生成真实且多样的交通场景。在设置车辆驾驶意图的情况下,TSG-GAN 模型可以精确地生成现实中未观察到的真实交通场景。通过在公开数据集上进行测试,验证了该模型的有效性。

**关键词:** 自动驾驶;交通场景生成;虚拟测试场景;生成对抗网络

中图分类号: U467.5 文献标识码: A 国家标准学科分类代码: 520.20

## Traffic scenario generation based on generative adversarial networks for autonomous driving

Jing Rongrong<sup>1</sup> Wu Lan<sup>2</sup> Zhang Kunpeng<sup>1,3</sup>(1. College of Electrical Engineering, Henan University of Technology, Zhengzhou 450001, China;  
2. College of Mechanical and Electrical Engineering, Henan University of Technology, Zhengzhou 450001, China;  
3. Department of Automation, Tsinghua University, Beijing 100084, China)

**Abstract:** Self-driving vehicles are an important part of intelligent transportation and a trend of future transportation. Improving the reliability of autonomous driving technology requires extensive testing of autonomous driving vehicles. However, conducting real-world road tests is costly and risky. It is especially important to build models to generate diverse and realistic traffic scenarios for testing autonomous driving techniques. A traffic scenario generation generative adversarial network model called TSG-GAN is proposed for the generation of traffic scenarios. The TSG-GAN model uses Generative Adversarial Networks to rapidly generate realistic and diverse traffic scenarios by using rich traffic scenario data (e.g., lane geometry, crosswalks, traffic signals, surrounding vehicles, etc.). With reasonable driving intentions of vehicles, the TSG-GAN model can precisely generate realistic traffic scenarios that are not observed in practice. The effectiveness of the proposed model is verified by testing on a publicly available dataset.

**Keywords:** autonomous driving; traffic scenario generation; virtual test scenario; generative adversarial networks

## 0 引言

自动驾驶技术自从诞生以来便引起了众多研究人员的关注,它对于改变人们的出行方式具有重要的意义<sup>[1]</sup>。自动驾驶汽车在现实世界部署前需要进行全面的测试,场景是自动驾驶测试的基础。传统的道路测试从大量的道路测试场景中发现自动驾驶系统的问题,然而这种方式既昂贵又低效。即使在过去几年中,公开可用的数据集<sup>[2-4]</sup>的数量

有所增加,但它们依然缺乏多样性的交通场景。基于专家经验的场景枚举生成方法虽然成本有所降低,但是仍然无法满足自动驾驶测试的需求。数字虚拟仿真场景生成方式由于在场景多样性、安全性以及生成效率等方面的巨大优势,已经成为当前自动驾驶领域的研究热点<sup>[5]</sup>。

大多数传统的场景生成模型都是基于由专家人工设计的成本函数<sup>[6-7]</sup>。这些成本函数考虑了各种理想的属性,其中包括与其他汽车的距离、交通信号、交通规则等。然而,

收稿日期:2022-10-28

\*基金项目:国家自然科学基金(61973103,62002101)项目资助

设计这些成本函数是复杂且耗时的。并且由于测试数据有限,传统的基于规则或人工设计模型的方法对未见过的驾驶场景缺乏概括性。Behbahani 等<sup>[8]</sup>使用模仿学习技术从专家的演示中学习,但由于自动驾驶控制是一个连续的决策问题,这种学习方式会产生复合误差。

由于基于人为定义规则提取测试场景的方式主观局限性过大,一些研究提出基于聚类的场景生成模型<sup>[9-11]</sup>。例如刘颖等<sup>[12]</sup>提出基于车辆和行人的运动方向、视野范围以及交通信号等特征区分不同的场景,聚类出 5 类紧急制动测试场景。聚类算法依据真实的交通数据集的内在特征,从而实现典型场景的自动快速生成。然而,现实交通场景中的各种噪声都会映射到交通数据集中,从而干扰聚类结果。这使得基于聚类的场景生成方法受限于数据集的采样精度、样本完整性。

一些研究提出基于随机采样的典型场景生成方法,主要包括蒙特卡洛方法和快速遍历随机树等算法。例如朱宇等<sup>[13]</sup>从高速公路数据集中提取真实的变道场景,分析场景中的特征参数,利用蒙特卡洛模拟生成变道场景。Yang 等<sup>[14]</sup>通过提取实车测试中的数据片段,依据场景参数的概率分布通过蒙特卡罗模拟生成了自动紧急制动的测试场景。基于随机采样的场景生成方法根据场景参数概率分布采样,从而生成与真实交通数据特征一致的交通场景。但这种方法缺陷在于会生成大量不合理的场景,并且可能会遗漏一些重要特征。

随着深度神经网络在众多领域的成功应用,一些研究尝试使用深度神经网络解决交通场景生成问题。例如 Jenkins 等<sup>[15]</sup>提出了一种基于递归神经网络的交通场景生成模型,利用已有的时间序列数据自动生成新的交通场景。近年来,得益于其出色的数据生成能力,生成对抗网络(generative generative adversarial network, GAN)<sup>[16]</sup>在图像生成等领域得到了广泛的应用。基于生成对抗网络的图像生成模型通常由卷积神经网络构成,但基于注意力机制的 Transformer<sup>[17]</sup>改变了这一情况。相对于卷积神经网络的局部感受野,注意力机制的全局感受野在图像生成方面更具优势。另外,Transformer 建模语义相关性和空间相关性的能力使得它能够更有效的提高生成图像的质量。Jiang 等<sup>[18]</sup>选择利用纯 Transformer 构造生成器和鉴别器,提出了 TransGAN,用于生成高分辨率图像。

生成对抗网络在图像生成方面的成功应用也使得人们将其扩展到了自动驾驶领域。一些研究尝试使用生成对抗网络解决自动驾驶交通场景生成问题。例如 Krajewski 等<sup>[19]</sup>提出轨迹生成对抗网络和轨迹变分自动编码器,从真实的车辆变道轨迹数据学习潜在特征来生成全新的车辆换道轨迹。Ding 等<sup>[20]</sup>结合双向编码器和多输出头解码器提出了一个多车轨迹生成器,通过生成多个车辆的轨迹来模拟车辆相遇的交通场景。此外,Demetriou 等<sup>[21]</sup>利用一种递归条件生成对抗网络(recurrent conditional generative

adversarial networks, RC-GAN)来生成可变长度的轨迹。然而,这些方法通过从真实的交通数据中挖掘数据特征,仅仅为目标车辆生成轨迹,对于模型性能的分析也仅限于轨迹生成能力,未能考虑各个车辆之间的交互关系。此外,由于车辆的意图不能被预先设定,这些研究无法定制车辆的驾驶行为。综上所述,上述方法无法直接应用于自动驾驶测试中。

为了有效地解决上述问题,生成真实且多样的交通场景,本文提出了基于生成对抗网络的交通场景生成模型(traffic scenario generation generative adversarial network, TSG-GAN)。具体来说, TSG-GAN 模型利用生成对抗网络对大量的交通场景数据进行学习,并基于互信息理论生成可定制化的交通场景。本文提出的方案允许模型根据设置的车辆驾驶行为标签,构建从未见过的场景,并针对自动驾驶汽车的行为做出合理的车辆行为规划。利用 Lyft<sup>[22]</sup> 数据集的真实交通场景数据对所提出的方案进行定性和定量分析,以验证其有效性。

## 1 交通场景生成模型建立

### 1.1 问题构建

在本文研究中,提出了一个基于生成对抗网络的交通场景生成模型 TSG-GAN。该模型利用丰富的交通场景数据来生成真实且多样的交通场景。图 1 是所提出的 TSG-GAN 模型的流程图。本研究假设自动驾驶车辆上配备的雷达和摄像头传感器的原始数据可以被准确地转变成两类数据:图像数据和数字数据,这些数据被当作 TSG-GAN 模型的输入。图像数据包括道路信息图、车辆位置图和具有相同高度  $H$  和宽度  $W$  的可达网格图。数字数据包括车辆驾驶行为标签(包括车道保持、停车、左侧车道变化、右侧车道变化、切入、超车、车道合并、调头和环岛)和交通场景中的车辆数目。此外, TSG-GAN 模型还采用了三种来自正态分布和伽马分布的抽样随机噪声来模拟交通场景中车辆运动的不确定性,它们可以为生成式模型提供随机噪声,使其可以生成更加多样的交通场景。

如图 1 所示,交通场景数据是各种驾驶场景序列的集合。每个驾驶场景指的是一定时间、空间范围内的所有景物和移动物体/实体的快照。这些原始的交通场景数据可以用鸟瞰图的方式进行表示。交通场景鸟瞰图包括:道路几何信息图、车辆位置图和可达网络图。其中,道路信息图包含场景中详细的道路信息,包括车道的几何形状、人行横道和交通信号,它是一个具有 3 个通道的 RGB 图像。车辆位置图显示了自动驾驶车辆和周围其他车辆的空间位置,它也是由 3 个通道的 RGB 图像表示。道路信息图和车辆位置图是在 Lyft 提供的软件包 15 kit 的帮助下生成的。可达网格图是一个单通道灰度图像,用来表示车辆可以到达的区域,作为一种先验知识,可以帮助模型快速收敛。为了表示各种车辆的驾驶意图,本研究在模型中引入了车辆

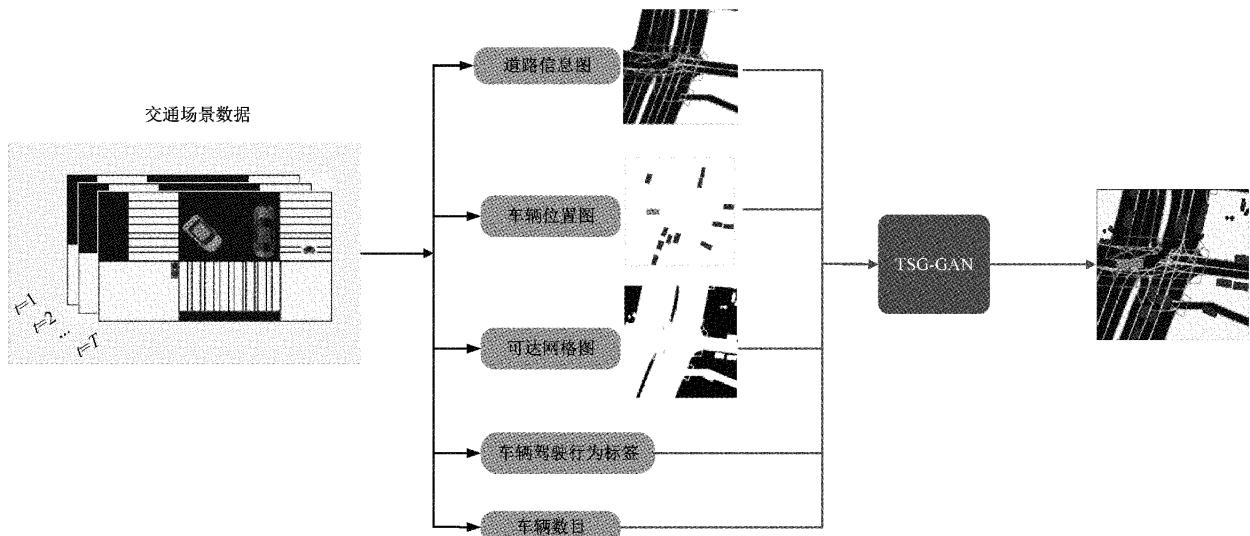


图 1 模型流程

驾驶行为标签,其中包括车道保持、停车、左侧车道变化、右侧车道变化、切入、超车、车道合并、调头和环岛。在车辆驾驶行为标签的帮助下,TSG-GAN 可以准确地生成相应的交通场景。

## 1.2 模型结构

利用丰富的交通场景数据,TSG-GAN 模型解决的关键问题是学习如何生成种类繁多且真实的交通场景。基于互信息理论,TSG-GAN 模型改进了原始的生成对抗网络模型。如图 2 所示,TSG-GAN 的结构与原始的生成对抗网络类似,同样由生成器 G 和鉴别器 D 组成。生成器 G 可以将噪声输入映射到观测值,鉴别器 D 可以对真实数据以及由生成器生成的数据进行比较来判断真假。与原始的 GAN 结构不同,TSG-GAN 的鉴别器 D 包含鉴别器主体  $D_B$ 、鉴别头  $D_G$  和识别头  $D_R$  三部分。鉴别头  $D_G$  判断输入到鉴别器主体  $D_B$  的数据是真还是假。识别头  $D_R$  尝试生成输入到生成器 G 的隐变量 C。与随机噪声 Z 相比,隐变量 C 由可操作变量(如车辆驾驶行为标签等)组成,从而使 TSG-GAN 模型具备了可以定制交通场景的能力。TSG-GAN 模型的详细结构如图 3 所示,其输入包括 3 种类型的随机噪声(即正态分布 Z、两个伽马分布  $C_x$  和  $C_y$ )、道路信息图、车辆位置图、可达网格图、车辆驾驶行为标签和车辆数目。在生成过程中,TSG-GAN 的生成器 G 以 3 种噪声(即 Z、 $C_x$  和  $C_y$ )、指定的车辆位置图 A、车辆驾驶行为标签 U、车辆数目 I、道路信息图 R 以及可达网格图 J 为输入生成定制的车辆位置图  $\hat{A}$ 。3 种类型的随机噪声可以为交通场景生成模型引入随机性,以确保所生成场景的多样性。此外,通过引入  $C_x$  和  $C_y$ ,可以在生成过程中对所选定的车辆速度进行一定程度的控制。

为了保证隐变量的有效性,引入互信息理论来保证 C 和  $G(Z, C)$ (即  $I(C; G(Z, C))$ )之间具有较高的互信息,

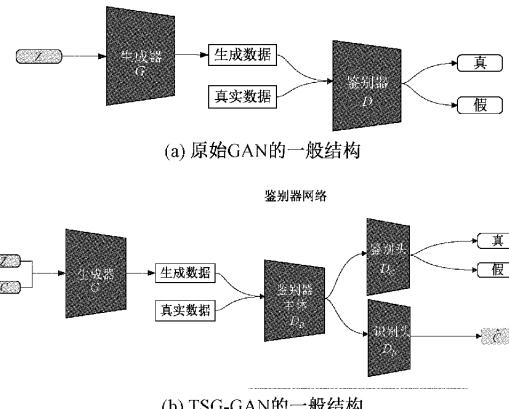


图 2 GAN 和 TSG-GAN 的一般结构

为此 TSG-GAN 模型引入了以下两个目标函数:

$$\min_{G,Q} \max_D V_{\text{TSG-GAN}}(D, G, Q) = V_{\text{GAN}}(D, G) - \lambda \cdot L_{\text{Info}}(G, Q) \quad (1)$$

$$I(C; G(Z, C)) \geq L_{\text{Info}}(G, Q) =$$

$$\mathbb{E}_{X \sim G(Z, C)} [\mathbb{E}_{\hat{C} \sim P(C, X)} [\log Q(\hat{C} | X)]] + H(C) \quad (2)$$

在式(1)中  $V_{\text{GAN}}(D, G)$  是一个原始 GAN 的目标函数,  $\lambda$  是加权系数,  $L_{\text{Info}}$  是互信系数  $I(C; G(Z, C))$  的下限。Q 作为一个辅助分布来近似  $P_G(C | X)$ , 它可由识别头  $D_R$  参数化。X 代表真实样本。 $\hat{C}$  是 C 的生成样本。在式(2)中,当辅助分布 Q 达到真实的后验  $P_G(C | X)$  时,下限也会收窄,即  $\mathbb{E}_{X \sim G(Z, C)} [\mathbb{E}_{\hat{C} \sim P(C, X)} [\log Q(\hat{C} | X)]]$  逐渐减小为 0。随着下限达到其最大值即当  $L_{\text{Info}}(G, Q) = H(C)$  时,接收隐变量 C 和生成器 G 之间的最大互信息。

如式(2)所示,通过两种类型的损失函数即对抗性损失  $V_{\text{GAN}}(D, G)$  和信息损失  $L_{\text{Info}}(G, Q)$ ,分两步训练 TSG-GAN,以交替优化生成器 G 和鉴别器 D。步骤 1) 中生成

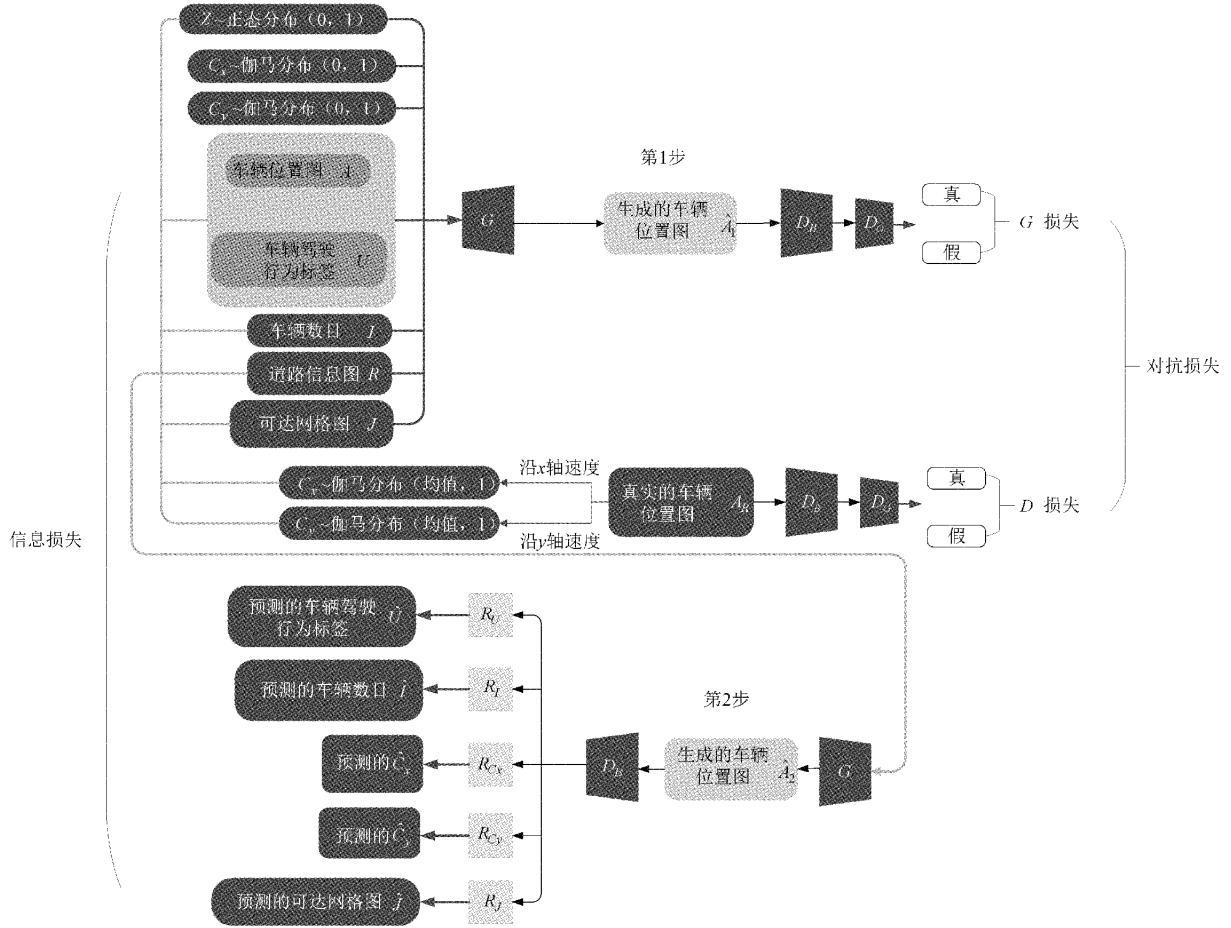


图 3 TSG-GAN 的模型结构

器  $G$  使用正态分布  $Z$ 、道路信息图  $R$ 、车辆位置图  $A$ 、车辆驾驶行为标签  $U$ 、车辆数目  $I$ 、沿  $x$  轴和  $y$  轴的速度(即  $C_x$  和  $C_y$ )以及可达网格图  $J$  作为输入,以生成未来 3 s 的车辆位置图  $\hat{A}_1$ 。然后,生成的车辆位置图  $\hat{A}_1$  和真实的车辆位置图  $A_R$  交替地输入到鉴别器  $D$  中,其中鉴别头  $D_G$  判断车辆位置图是否为真实的。最后,计算对抗损失  $V_{GAN}(D, G)$  以优化生成器  $G$  和鉴别器  $D$ 。步骤 2) 将步骤 1) 输入中的  $C_x$  和  $C_y$  替换为伽马分布,其形状参数为实际车辆速度沿  $x$  轴和  $y$  轴平均值,尺度参数为 1。将步骤 1) 相应的  $Z, R, A, U, I$  以及新的  $C_x$  和  $C_y$  作为新的生成器  $G$  的输入用以生成车辆位置图  $\hat{A}_2$ 。随后将生成的车辆位置图  $\hat{A}_2$  作为鉴别器主体  $D_B$  的输入,其输出被馈入识别头  $R_U$ 、 $R_I$ 、 $R_{C_x}$ 、 $R_{C_y}$  和  $R_J$  以预测车辆驾驶行为标签  $\hat{U}$ 、车辆数目  $\hat{I}$ 、沿  $x$  轴的速度  $\hat{C}_x$  和沿  $y$  轴的速度  $\hat{C}_y$  以及可达网格图  $\hat{J}$ 。通过计算信息损失  $L_{Info}(G, Q)$  来更新生成器  $G$  和鉴别器  $D$  的参数,对它们进行再次优化。

车辆驾驶行为标签  $U$ 、车辆数目  $I$  和可达网格图  $J$  与预测的车辆驾驶行为标签  $\hat{U}$ 、车辆数目  $\hat{I}$  和可达网格图  $\hat{J}$

之间的差异由平均绝对误差(mean absolute error, MAE)计算。真实速度(即  $C_x, C_y$ )和预测速度(即  $\hat{C}_x, \hat{C}_y$ )之间的差异由 Wasserstein Distance (WD)来衡量。借助于信息损失  $L_{Info}(G, Q)$ ,可以优化生成器  $G$  和鉴别器  $D$ ,以在 TSG-GAN 的训练过程中保留  $U, I, C_x, C_y$  和  $J$  的信息,保证了模型在生成定制交通场景方面的良好性能。

## 2 实验与分析

### 2.1 数据集来源

本研究使用 Lyft 提供的交通场景数据来训练和测试 TSG-GAN 模型。这个数据集包含了自动驾驶车辆沿美国加利福尼亚州帕洛阿尔托市郊路线的 1 118 h 的驾驶记录,收集了 20 辆自动驾驶车辆及其周围交通参与者(如车辆、自行车、行人)的运动轨迹。该数据集提供了详细的高清地图,包含 15 242 个标记元素,标注了车道几何、道路规则和其他交通元素。此外,Lyft 数据集中还包含了交通场景中交通信号的变化。

在训练和测试 TSG-GAN 模型时,使用 Lyft 数据集中的 16 265 个交通场景进行训练,并选取 16 220 个交通场景来进行测试。选择直行、左转、右转和超车等驾驶意图来

测试 TSG-GAN 的交通场景生成能力。基于原始数据,利用 Lyft 提供的 15 kit 软件包生成交通场景的鸟瞰图,其高度和宽度为 224 像素,每个像素对应 0.5 m。

## 2.2 模型性能对比

利用 TSG-GAN 模型生成真实的交通场景时,需要考虑 3 个设计原则:安全性、多样性和实时性。在安全性方面,生成的车辆运动应该遵守基本的交通规则,以确保所生成的交通场景符合现实法规和逻辑。至于多样性,TSG-GAN 应该能够提供各类驾驶行为,以确保可以生成足够多样的交通场景。就实时性而言,现实交通场景中,车速往往比较快,给自动驾驶系统的反应时间非常短。因此,TSG-GAN 还应具有较短的推理时间以满足实时性需求。

根据这 3 个设计原则,引入了 3 个指标来评估 TSG-GAN 模型的性能。为了验证 TSG-GAN 模型的安全性,引入了缺陷预测(flawed prediction,FP)来统计违反交通信号的预测次数、非道路(超出可驾驶区域)的预测次数和碰撞(包括正面碰撞、侧面碰撞和背面碰撞)的预测次数。FP 值越小,表明模型越安全。同时引入了平均最终位移误差(final displacement error,FDE)与最小 FDE 的比率(ratio of FDE,RF)来衡量 TSG-GAN 生成轨迹的多样性,其计算公式为:

$$RF = \frac{FDE_{avg}}{FDE_{min}} \quad (3)$$

RF 的值越大,意味着模型生成多样性场景的能力越强。最后推理时间用于反应模型是否满足实时性,所需推理时间越短则代表模型推理速度越快,更能满足实时性需求。

此外,引入了 3 个对比模型来验证 TSG-GAN 模型的优越性。

1) ResNet<sup>[23]</sup>: 残差网络(residual network,ResNet)基于卷积神经网络,使用残差连接解决深度网络训练时存在的梯度消失、梯度爆炸以及性能退化等问题。在 ResNet 模型中,没有引入随机噪声作为输入,其余输入与 TSG-GAN 模型的输入相同。

2) CGAN<sup>[24]</sup>: 条件生成对抗网络(conditional GAN,CGAN)将额外的条件信息作为输入,可以使模型生成定制的交通场景。CGAN 模型具有与 TSG-GAN 相同的模型结构,但没有可解释的隐变量 C 和信息损失函数。

3) TransGAN: TransGAN 是一种全新的改进型生成对抗网络。其整体的原理与传统的生成对抗网络相同,不同之处在于 TransGAN 的生成器和鉴别器都是用 Transformer 构造的。此外,TransGAN 还提出了使用网格自注意力机制取代标准的自注意力机制以提升模型性能。

分别将 TSG-GAN、ResNet、CGAN 和 TransGAN 在相同计算机上执行 100 次,然后计算模型的 FP、RF 和推理时间,并记录结果。从表 1 中可以发现,CGAN 的 FP 是最

高的( $FP=51$ ),ResNet 次之( $FP=5$ ),TransGAN 的 FP 则要更小一点( $FP=3$ ),而 TSG-GAN 的 FP 是四个模型中最小的( $FP=1$ )。这表明 TSG-GAN 是这四个模型中缺陷预测最少的,说明该模型在安全性上优于其他三个模型。其次,CGAN 的 RF 最高( $RF=3.021$ )优于 TSG-GAN( $RF=2.973$ )、TransGAN( $RF=2.759$ )和 ResNet( $RF=2.156$ )。这表明 CGAN 在生成场景的多样性上要优于 TSG-GAN、TransGAN 和 ResNet。虽然 TSG-GAN 生成场景的多样性不如 CGAN,但 CGAN 的 FP 高达 51,说明其安全性非常糟糕。表 1 中还展示了 4 个模型的推理时间,相同情况下,TSG-GAN 模型的推理时间为 11.3 s,少于其他 3 个模型。而 TransGAN 所花费的推理时间为 31.6 s,远高于其他模型。这可以解释为 Transformer 的使用使得 TransGAN 的参数量大大增加,导致其计算效率降低,难以满足自动驾驶测试的实时性需求。总的来说,TSG-GAN 模型在保证生成场景的安全性的同时又拥有良好的多样性,并且所需的推理时间最短,该模型的综合性能优于其他 3 个模型。

表 1 4 种模型性能对比

衡量指标	ResNet	CGAN	TransGAN	TSG-GAN
FP	5	51	3	1
RF	2.156	3.021	2.759	2.973
推理时间/s	13.8	15.0	31.6	11.3

图 4 中显示了 TSG-GAN 模型执行 10 次所生成的目标车辆在十字路口的 10 条运动轨迹。其中,目标车辆用红色方块表示,其他车辆用蓝色方块表示,可行驶车道为灰色,人行横道的颜色为橙色,绿色车道表示该车道的交通信号灯此时为绿色,可通行。可以看出,TSG-GAN 模型为目标车辆生成了多种运动轨迹,而且生成的运动轨迹合理地遵守了基本的交通规则。

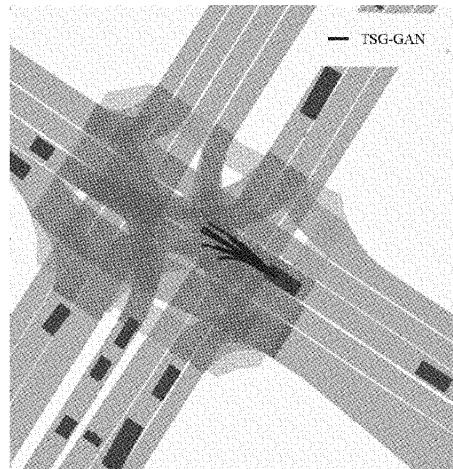


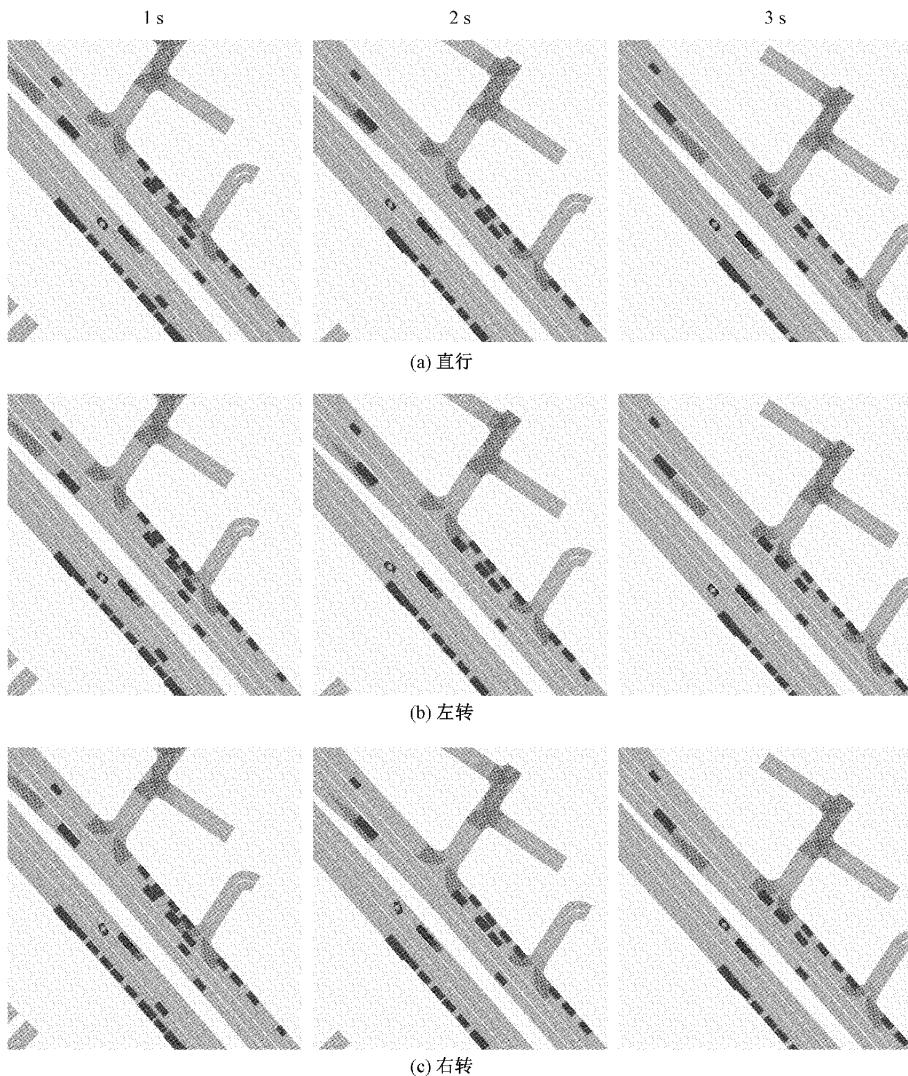
图 4 由 TSG-GAN 生成的目标车辆的运动轨迹

### 2.3 定制目标车辆驾驶行为

TSG-GAN 的特点在于可以通过给车辆分配不同的驾驶意图来操控场景中车辆的驾驶行为,从而生成定制的交通场景。上一节验证和测试了 TSG-GAN 生成多样性和安全性驾驶行为的能力。本节进一步测试 TSG-GAN 是否可以通过给车辆分配不同的驾驶意图(即直行、左转和右转)和一个具有挑战性的驾驶意图(即超车)来生成车辆的各种行为。在实验中,首先选定自动驾驶汽车(self-driving vehicles, SDVs)周围的一个车辆以执行各种预定的驾驶意图。例如,对于超车驾驶意图,选择 SDV 后方有超车权的车辆作为目标车辆。然后,该车辆的车辆驾驶行为标签被替换为“超车”,而交通场景中其他车辆的车辆驾驶行为标签保持不变。TSG-GAN 模型以适当的车辆驾驶行为标签和车速作为输入,以达到控制目标车辆驾驶行为的目的。

在图 5 中,红色渐变方块表示 SDV 及其历史位置,周围的车辆为蓝色方块,其中标有橙色圆点的为所选定的目标车辆。对于直行、左转、右转的驾驶场景, TSG-GAN 给

选定的目标车辆分配意图,并生成相应的驾驶行为。以生成 3 s 的交通场景为例,图 5(a)~(d)分别展示了模型生成的 4 个不同的交通场景。这些交通场景中的车辆都具有相同的初始状态,不同的是目标车辆被分配了不同的驾驶意图。图 5(a)中目标车辆被给予了保持车道直行的驾驶意图,从图中可以观察到该车辆很好地执行了所给定驾驶意图,始终保持在原本的车道内直行,并未出现左转或右转的倾向。图 5(b)中所选定的目标车辆被分配了左转的驾驶意图,在第 1 s 时目标车辆便表现出了左转的倾向,并在 3 s 内完成了整个左转的过程。图 5(c)与图 5(b)类似,目标车辆被分配了右转的驾驶意图,并且在 3 s 内完成了整个右转变道的过程。TSG-GAN 模型还可以生成较为复杂的超车场景。如图 5(d)所示,在第 1 s 时目标车辆在 SDV 后方开始右转准备进行超车,并在接下来的 2 s 内超越了 SDV,并表现出向左换道,完成超车的动向。此外,目标车辆执行超车意图的 3 s 内始终与 SDV 保持了安全距离,避免了碰撞的发生。



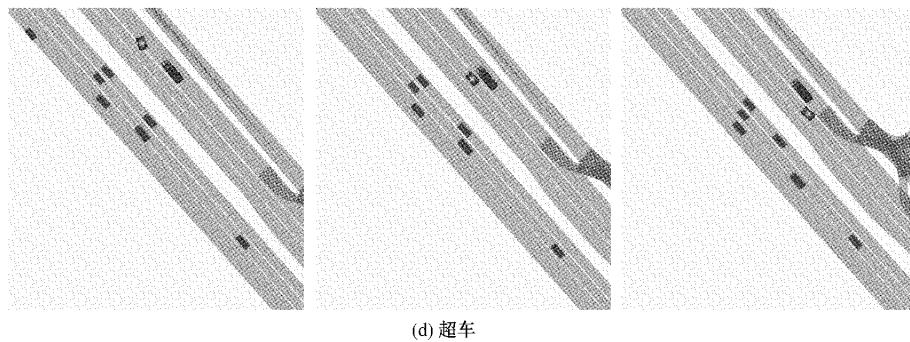


图 5 以 4 种驾驶意图作为条件生成的交通场景

从图 5(a)~(d)可以观察到,目标车辆产生的驾驶行为跟预先给定的车辆驾驶行为标签相符。从而可以得出结论,TSG-GAN 模型能够通过预先对场景中的车辆设置各种驾驶意图生成各类合理的驾驶行为。

#### 2.4 生成复杂交通场景

在上一节中验证了 TSG-GAN 模型定制目标车辆驾驶行为的能力,这一节将进一步探讨该模型生成复杂交通场景的能力。首先应当明确的是在道路环境一定的情况下,SDV 周围车辆的个数、这些车辆与 SDV 的相对位置以及这些车辆可能的运动轨迹是场景生成的关键内容。此外,交叉路口的场景的生成能力是衡量交通场景生成模型的重要指标。本节旨在测试 TSG-GAN 的交叉路口场景生成能力。图 6 是一个交叉路口,其中 A 车、B 车和 C 车

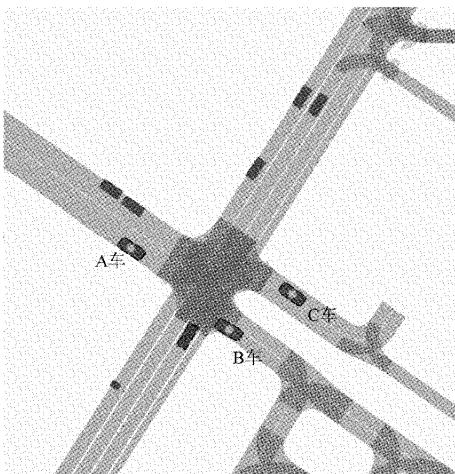


图 6 交叉路口可能的车辆分布

表 2 3 辆车可能的驾驶行为组合

SDV	A 车	B 车	C 车
直行	红灯等待	直行	红灯等待
	红灯等待	直行	右转
	直行	直行	直行
	直行	直行	右转
	左转	直行	直行
	左转	直行	右转
	右转	直行	红灯等待
	右转	直行	直行
	右转	直行	右转

是对 SDV 运动存在影响的车辆。根据一般的交通规则,3 辆车可能的驾驶行为组合如表 2 所示。随着场景中车辆数量的增多,TSG-GAN 可以生成的复杂测试场景数量也会成倍增加。图 7 所示为 TSG-GAN 模型生成的部分交通场景示例。其中红色渐变方块表示 SDV 及其历史位置,标有橙色圆点的蓝色渐变色方块表示周围车辆及其历史位置。图 7(a)~(c)分别是 A 车在交叉路口执行直行、左转和右转的驾驶意图。图 7(d)~(f)构建了更为复杂的测试场景,分别是 A 车左转 B 车直行、A 车左转 C 车右转和 A 车左转 B 车直行 C 车右转。可以看出,A 车、B 车和 C 车在行进过程中会对 SDV 的运动产生一定程度的干扰,但又始终保持着安全距离。

因此可以得出结论,TSG-GAN 可以在预先设置车辆驾驶意图的情况下,生成有测试价值的复杂交叉路口场景。

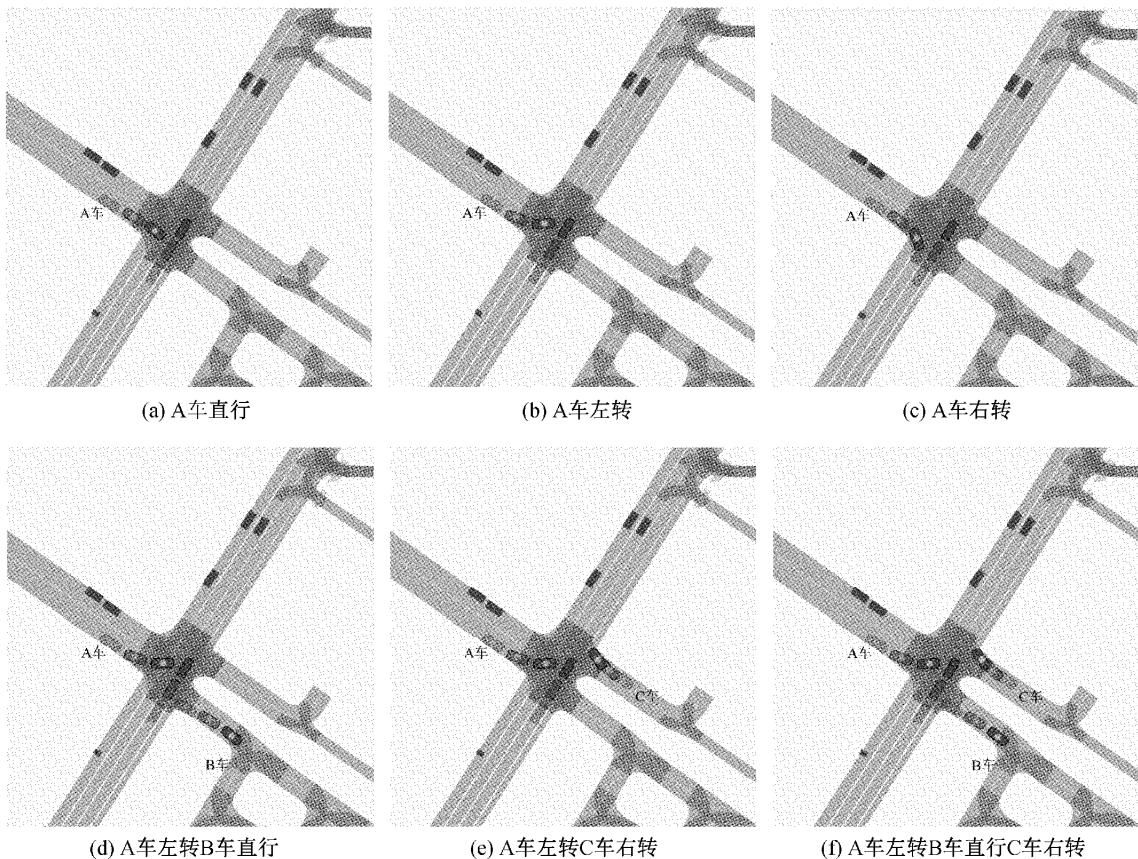


图 7 生成的交通场景示例

### 3 结 论

针对自动驾驶交通场景生成问题,本文提出了基于生成对抗网络的交通场景生成模型。所提出的模型利用丰富的交通场景数据,在设置车辆驾驶意图的情况下,精确地生成多样且真实的交通场景。

本文从实验中得出以下结论:

1) 基于生成对抗网络和互信息理论,提出的 TSG-GAN 模型可以从交通场景数据中学习场景数据特征,并自动生成所需的测试场景。大大节省了人力和时间成本,这对于自动驾驶车辆的测试具有十分重要的意义。

2) 通过以适当的车辆驾驶行为标签和车速作为输入,TSG-GAN 可以操控场景中的目标车辆并生成对应的驾驶行为。

3) 在预设场景中车辆驾驶意图并生成对应驾驶行为的基础上,TSG-GAN 可以在考虑安全性和多样性的前提下,自动生成有测试价值的复杂交通场景。

尽管 TSG-GAN 可以通过预先设置场景中车辆的驾驶意图来生成定制的交通场景,并且这些交通场景都考虑了安全性和合理性。但所提出的方法未考虑生成一些危险性的场景,用于自动驾驶汽车的强化测试,这部分内容将在未来作进一步研究。

### 参 考 文 献

- [1] 于方程,张小俊,张明路,等. 基于改进 CenterNet 的自动驾驶小目标检测[J]. 电子测量技术,2022,45(15): 115-122.
- [2] ZHAN W, SUN L T, WANG D, et al. INTERACTION dataset: An INTERnational, adversarial and cooperative moTION dataset in interactive driving scenarios with semantic maps[J]. ArXiv Preprint, 2019, ArXiv:1910.03088.
- [3] SUN P, KRETZSCHMAR H, DOTIWALLA X, et al. Scalability in perception for autonomous driving: Waymo open dataset[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 2446-2454.
- [4] KRAJEWSKI R, BOCK J, KLOEKER L, et al. The highd dataset: A drone dataset of naturalistic vehicle trajectories on german highways for validation of highly automated driving systems [C]. 2018 21st International Conference on Intelligent Transportation Systems(ITSC), IEEE, 2018: 2118-2125.
- [5] 邓伟文,李江坤,任秉楠,等. 面向自动驾驶的仿真场景自动生成方法综述[J]. 中国公路学报,2022, 35(1):18.

- [6] FAN H Y, ZHU F, LIU C C, et al. Baidu apollo EM motion planner [J]. ArXiv Preprint, 2018, ArXiv:1807.08048.
- [7] ZIEGLER J, BENDER P, DANG T, et al. Trajectory planning for bertha—A local, continuous method[C]. 2014 IEEE Intelligent Vehicles Symposium Proceedings, IEEE, 2014: 450-457.
- [8] BEHBAHANI F, SHIARLIS K, CHEN X, et al. Learning from demonstration in the wild[C]. 2019 International Conference on Robotics and Automation (ICRA)(2019): 775-781.
- [9] PÜTZ A, ZLOCKI A, KÜFEN J, et al. Database approach for the sign-off process of highly automated vehicles[C]. 25th International Technical Conference on the Enhanced Safety of Vehicles (ESV) National Highway Traffic Safety Administration, 2017: 1-8.
- [10] 李霖, 朱西产, 刘颖, 等. 涉及骑车人的典型交通危脸场景[J]. 同济大学学报(自然科学版), 2014, 42(7):1082-1087.
- [11] 任立海, 夏环, 蒋成约, 等. 基于交通事故数据的自动紧急制动系统测试场景构建[J]. 科学技术与工程, 2022, 22(24):10737-10747.
- [12] 刘颖, 贺锦鹏, 刘卫国, 等. 自动紧急制动系统行人测试场景的研究[J]. 汽车技术, 2014(3): 35-39.
- [13] 朱宇, 赵祥模, 徐志刚, 等. 基于蒙特卡洛模拟的无人车高速公路变道虚拟测试场景自动生成算法[J]. 中国公路学报, 2022, 35(3):89-100.
- [14] YANG H H, PENG H. Development and evaluation of collision warning/collision avoidance algorithms using an errable driver model [J]. Vehicle System Dynamics, 2010, 48(S1): 525-535.
- [15] JENKINS I R, GEE L O, KNAUSS A, et al. Accident scenario generation with recurrent neural networks[C]. 2018 21st International Conference on Intelligent Transportation Systems (ITSC). Maui, HI, USA: IEEE, 2018: 3340-3345.
- [16] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets [J]. Advances in Neural Information Processing Systems, 2014, 27.
- [17] VASWANI A, SHAZER N, PARMAR N, et al. Attention is all you need [J]. Advances in Neural Information Processing Systems, 2017, 30.
- [18] JIANG Y, CHANG S, WANG Z. Transgan: Two transformers can make one strong gan [J]. ArXiv Preprint ArXiv:2102.07074, 2021, 1(3).
- [19] KRAJEWSKI R, MOERS T, NERGER D, et al. Data-driven mancuver modeling using generative adversarial networks and variational autoencoders for safety validation of highly automated vehicles[C]. IEEE, 2018 21st International Conference on Intelligent Transportation Systems (ITSC). New York: IEEE, 2018:2383-2390.
- [20] DING W, WANG W, ZHAO D. A multi-vehicle trajectories generator to simulate vehicle-to-vehicle encountering scenarios[C]. IEEE. 2019 International Conference on Robotics and Automation(ICRA). New York: IEEE, 2019:4255-4261.
- [21] DEMETRIOU A, ALFSVÅG H, RAHROVANI S, et al. A deep learning framework for generation and analysis of driving scenario trajectories [J]. ArXiv Preprint, 2020, ArXiv:2007.14524.
- [22] HOUSTON J, ZUIDHOF G, BERGAMINI L, et al. One thousand and one hours: Self-driving motion prediction dataset[C]. Conference on Robot Learning. PMLR, 2021: 409-418.
- [23] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [24] MIRZA M, OSINDERO S. Conditional generative adversarial nets [J]. ArXiv Preprint, 2014, ArXiv: 1411.1784.

### 作者简介

景荣荣,硕士研究生,主要研究方向为自动驾驶轨迹预测算法。

E-mail:AlbertJing@stu.haut.edu.cn

吴兰(通信作者),博士生导师,博士,教授,主要研究方向为人工智能、智能交通等。

E-mail:wulan@haut.edu.cn

张坤鹏,硕士生导师,博士,副教授,主要研究方向为智能交通系统和自动驾驶。

E-mail:kp.zhang@outlook.com