

DOI:10.19651/j.cnki.emt.2415572

基于风险场景搜索的自动驾驶测试方法

丁浩天 王国权

(北京信息科技大学机电工程学院 北京 100192)

摘要: 自动驾驶测试方法是自动驾驶研究体系中重要的组成部分,也是当前研究的热点之一。提出了基于风险场景搜索的自动驾驶测试方法,通过 NGSIM 数据集提取出换道场景,确定场景参数空间范围和特征,通过基于遗传算法的场景搜索方法构建自动驾驶测试场景。为了提高场景生成效率,改进了场景参数的搜索过程,对前车换道场景设置了约束,对单个场景的仿真时间进行优化,增加了记忆模块以防止相同场景进行复测试。基于 PreScan/Simulink 平台构建了三车道前车换道场景,生成并完成了 439 个场景的测试,其中有 266 个场景发生了车辆碰撞。分析发现,碰撞失效是由于被测算法制动不及时和未触发紧急制动所导致。

关键词: 自动驾驶;场景生成;遗传算法;虚拟测试

中图分类号: U467.1;TN06 **文献标识码:** A **国家标准学科分类代码:** 520.20

Autonomous driving testing approach based on risky scenario search

Ding Haotian Wang Guoquan

(School of Electromechanical Engineering, Beijing Information Science & Technology University, Beijing 100192, China)

Abstract: Autonomous driving test method is an important part of autonomous driving research systems, and it is also one of the current research hotspots. In this paper, an automatic driving test method based on risk scenario search is proposed. The swap scenario is extracted through the NGSIM (Next Generation Simulation) dataset, and the scope and characteristics of the scene parameter space are determined. To improve the efficiency of scene generation, the search process of scene parameters is enhanced, constraining the lane-changing scene of the preceding vehicle, optimizing the simulation time of a single scene, and adding a memory module to prevent the same scene from repeated testing. A three-lane leading vehicle lane-changing scenario is constructed based on the PreScan/Simulink platform, and 439 scenarios are generated and tested, among which 266 scenarios result in vehicle collisions. It is found that collision failures are caused by the delayed action of the measuring system and the failure to trigger emergency braking.

Keywords: autonomous driving; scene generation; genetic algorithm; virtual testing

0 引言

近年来,随着自动驾驶技术的广泛应用,对其智能性、安全性等性能进行全面测试变得迫在眉睫。然而传统基于实际道路的测试存在高风险和费时费力的问题。虚拟仿真测试方法的引入为解决这些问题提供了一种行之有效的途径^[1]。虚拟仿真测试的关键是大规模场景的自动生成问题。目前解决这个问题的方法主要有两种:其一是用较少的测试次数达到较高测试场景覆盖度;其二是发掘真实道路场景中发生概率较小但极易造成系统失效的场景,也就是生成高风险场景。

对于提升场景覆盖度的方法,研究者主要提出了组合测试方法、随机抽样等方法。舒红等^[2]提出了基于成对独

立组合测试(pairwise independent combinatorial testing, PICT)的场景构建方法,对路段场景和无红绿灯的十字路口场景进行生成,显著地减少测试次数。朱宇等^[3]提出基于随机采样中的蒙特卡洛模拟方法生成大量变道轨迹,保证所生成的变道轨迹与真实轨迹具有相似性。Yan 等^[4]提出模拟自然驾驶环境时,环境统计的概率分布需要与真实驾驶环境的概率分布一致,并依此构建了随机人类驾驶员模型。这些方法能在保证场景覆盖度的情况下,减少测试次数。但同时也会生成大量的与真实场景相似冗余场景,对于极端情况下车辆自动驾驶性能测试有一定局限性。

对于生成高风险场景的方法,很多学者将交通参与者之间的交互描述成一个优化搜索问题^[5]。当前常用的优化搜索算法有差分进化法、粒子群优化算法(particle swarm

optimization, PSO)、模拟退火算法(simulated annealing, SA)、遗传算法(genetic algorithm, GA)及多目标搜索算法等。Kluck 等^[6]对比了不同优化算法的性能。在自动驾驶测试中,遗传算法可以通过执行最少的测试次数生成边界场景。但传统遗传算法中存在可能陷入局部最优、算法参数需要根据场景调整、依赖初始种群、运行后期会产生趋同个体等问题。当前研究中改进遗传算法有两个主要方向^[7]:

1) 设计高效的优化算法快速收敛到最优解。Eshelman^[8]提出了 CHC 改进遗传算法,CHC 表示跨代精英选择策略(C)、异物种重组(H)和大变异(C)三种策略的组合。Srinivas 等^[9]提出了非支配排序遗传算法(non-dominated sorting genetic algorithms, NSGA),对选择再生方法进行改进,将每个个体按照它们的支配与非支配关系进行分层,再做选择操作。Deb 等^[10]提出的 NSGA-II 算法采用精英策略防止优秀个体的流失,通过将父代和子代所有个体混合后进行。

2) 设计合理多样化的目标函数引导搜索方向。通过合理设置适应度函数^[11]也可以提升搜索最大风险场景的效率。常见的场景风险量化指标有:最小安全距离、碰撞时间(time to collision, TTC)^[6]、车头时距(time headway, THW)以及车辆与障碍物碰撞时间的成本函数^[5]。也可以用碰撞概率^[12]作为优化的最终目标。李春银^[13]提出了使用层次分析法建立目标函数,通过遗传算法生成大量匝道合流交通场景,保证生成场景逐渐趋向于高风险。Romanovsky 等^[11]提出一种场景适应度函数构造模板,帮助测试工程师解决了复杂场景的构造问题。

基于优化的场景生成方法避免了工程师和专家的主观决策对场景生成结果的影响,通过优化求解快速地发现可能导致系统故障的场景,很大程度提升了测试效率。设计出满足测试场景需求合适的成本函数是复杂且耗时的^[14],所以多数研究对于适应度函数设置过于简单,且仅针对系统初始参数进行约束并假设场景中所有交通参与者的状态不变,缺乏对动态场景演化过程中风险度的评价。

为了解决上述问题,有学者提出了将场景生成和系统测试结合的闭环在线生成方法^[7],即将被测系统视为黑盒系统,通过被测系统的实时反馈来修正场景参数^[15]。Lee 等^[16]首次提出自适应压力测试场景生成方法,通过与环境的实时交互能够有效地搜索导致事故发生率最高的切入轨迹。Mullins 等^[17]提出了一种新的自适应搜索方法,解决了在边界场景区域优先采样的问题,能够使用最小的样本数量生成有效的边界场景。此方法可以大量生成现实情况中概率极小的高风险、新奇的场景,但是还存在着生成重复场景或不可避免的碰撞场景。

综上所述,本文选择使用遗传算法结合在线仿真测试的方法完成自动驾驶场景生成及测试。传感器分辨率也会影响自动驾驶性能,当车速或车距变化极小时,车辆感知系

统会认为车辆状态未发生改变。所以本文采用离散参数空间,离散步长则采用传感器最小分辨率可以识别的步长,在不影响测试场景性能前提下,大幅减少搜索范围。同时延续传统遗传算法的改进思路,对适应度函数和遗传算子中的变异部分进行改进。传统适应度函数通常为工程师根据经验制定的函数公式或经典衡量场景风险度的参数,本文引入了 PreScan/Simulink 在线仿真的方式,将 TIT^{-1} (time integrated TTC 指标的倒数)和碰撞强度作为适应度函数。为了保证生成场景丰富度的同时保证进化速度,对变异算子进化方向和进化步长进行约束。与传统改进方法不同的是对在线仿真部分进行改进:1)增加了记忆模块,防止对重复场景进行测试;2)增加了场景约束模块,防止必然碰撞场景出现;3)根据场景参数自适应调节每次仿真停止时间。

1 自然驾驶数据处理

1.1 前车换道场景模型构建

以前车换道(Cut-In)场景为例,主车(equipment under test, EUT)在长直公路上正常行驶,前车(equipment target, ET)以小于主车的速度从右侧车道中换道进入主车所在车道,对主车行驶产生一定程度的阻碍,从而验证主车搭载的自动紧急制动系统(autonomous emergency braking system, AEBs)的性能,前车换道的模型如图 1 所示。

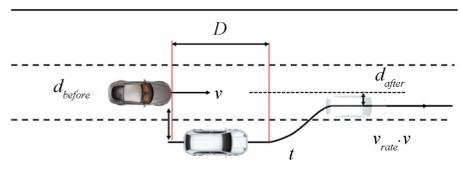


图 1 前车换道场景模型

依据两车的运动状态及空间位置将前车换道场景抽象为 6 个参数,通过优化算法对其进行搜索,符号及含义如表 1 所示。

表 1 场景参数矩阵符号及含义

变量	含义
d_{before}	在不同车道时前车与车道中心的横向偏移距离,大于 0 表示向左偏移,反之则向右偏移
D	前车开始换道动作时两车的纵向距离
v	本车速度
v_{rate}	前车速度,为了防止出现前车速度大于本车速度情况,将其含义设定为前车与本车速度之比(有效场景中此数值小于 1)
t	换道时间
d_{after}	本车换道后与车道中心线的横向偏移距离

1.2 数据集介绍

本文采用美国交通运输部的公开数据集 NGSIM(next generation simulation)提取出换到场景参数的取值范围和

分布概率作为本文场景建模参数。NGSIM 数据集时在指定路段安装高空摄像头采集,记录各类型车辆的轨迹信息,可以通过 Transportation.gov 网站获取。所使用的数据为 NGSIM 数据集中 US-101 路段,检测区长度 600 m,采集时间为上午 7:50~8:05,检测频率为 10 Hz,车道宽度约为 3.66 m,路段道路结构如图 2 所示,原始数据变量名称及说明如表 2 所示。数据集使用英制(feet,feet/s)单位,在进行处理前需要将单位换算为 m 和 m/s。

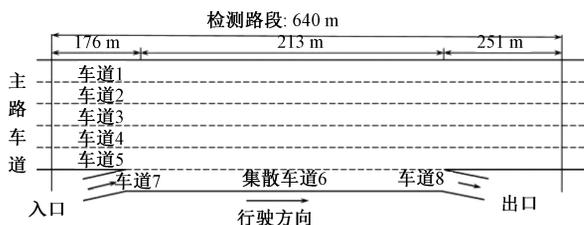


图 2 US-101 路段结构

表 2 US-101 路段原始数据变量名称及说明

字段	描述
Vehicle_Id	车辆识别号
Frame_Id	该条数据在某一时刻的帧,同一 Vehicle_ID 的帧号不会重复
Global_Time	时间戳/ms
Local_X	车辆前部中心的横向坐标,以英尺为单位,相对于截面在行驶方向上的最左侧边缘。
Local_Y	车辆前部中心的纵向坐标,以英尺为单位,相对于截面在行驶方向上的进入边缘。
v_Class	车辆类型:1-摩托车,2-汽车,3-卡车
v_Vel	车辆瞬时速度,以英尺/秒为单位
v_Acc	车辆的瞬时加速度,以英尺/秒为单位
Lane_ID	当前所在车道。第 1 车道是最左边的车道;第 5 车道是最右边的车道。

1.3 换道数据提取

NGSIM 数据中包含各种驾驶行为,为了保证车辆性能和驾驶行为的影响,需要筛选出汽车(type=2)的换道过程轨迹及周围车辆轨迹。

车道并非绝对直线,不能通过简单横向坐标变化来筛选换道场景,且数据集不存在车辆航向角信息,所以通过车辆横向加速度来判断车辆当前状态。一般认为车辆连续 0.5 s 横向速度大于 0.2 m/s 视为进行变道操作。横向速度需要通过 Local_X 进行积分得到,由于采样频率为 10 Hz,采样点较为稀疏,所以 Local_X 并非平滑曲线,积分后即使微小的变化也会导致数据突变。为了避免突变对实验结果产生影响,采用卡尔曼滤波对车辆横向坐标进行平滑处理。以 Vehicle_Id=18 的车辆为例,经过卡尔曼滤波前后的车辆横向坐标和速度的水平分量如图 3 和 4 所示。

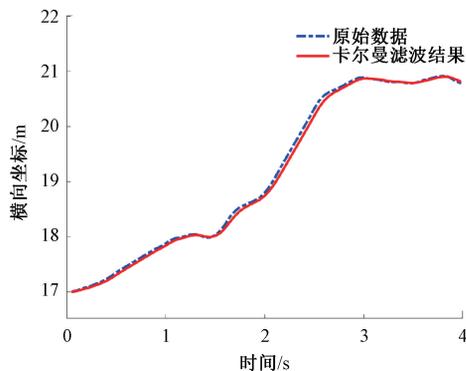


图 3 车辆横向坐标卡尔曼滤波前后对比

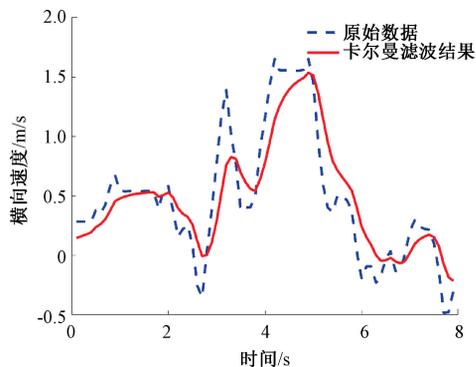


图 4 车辆横向速度卡尔曼滤波前后对比

通过对比分析观察到,稀疏采样点对车辆横向坐标的影响较小。然而,在对横向坐标进行积分以获取车辆横向速度时,滤波前后呈现出显著的差异,未经滤波的数据对于提取换道场景造成了明显的影响。通过上述数据处理步骤,共筛选出 224 组换道场景数据。

1.4 换道场景参数空间特征提取

对平滑处理后的车辆横向速度进行处理得到的换道时间,换道时间参数 t 取值范围为 $[0.985\ 3, 6.123\ 7]$ s,统计结果如图 5 所示,呈正态分布,均值为 3.554 5,方差为 0.995 82²。车辆横向偏移 d_{after} 和 d_{before} 在自然驾驶数据处理时作为一个参数进行处理,取值范围为 $[-0.861\ 9, 0.911\ 1]$ m,统计分布如图 6 所示,也呈正态分布,均值为 0.024 6,方差为 0.343 6²。换道时辆主车与前车距离 D ,在剔除纵向距离大于 100 m 和无车的情况少数情况后,取值范围为 $[4.020\ 4, 89.533\ 4]$ m,统计结果如图 7 所示,呈对数正态分布,其均值为 $\exp(2.943 + 0.601\ 4^2/2)$ 。对主车速度和前车速度进行提取,以主车速度为基础,计算前车速度与主车速度之比,当二者之比大于 1 时为安全场景,主车速度取值范围为 $[6.094\ 5, 28.064\ 3]$ m/s,两车速度比取值范围为 $[0.566\ 9, 1.493\ 7]$,统计结果如图 8 和 9 所示。

以统计量概率值 99% 为依据提取道路特征参数,正态分布的取值区间为 $[\mu - 2.58\sigma, \mu + 2.58\sigma]$,对数正态分布取值的区间为 $[\exp(\mu - 2.58\sigma), \exp(\mu + 2.58\sigma)]$ 。换道场景参数空间特征提取数据如表 3 所示。

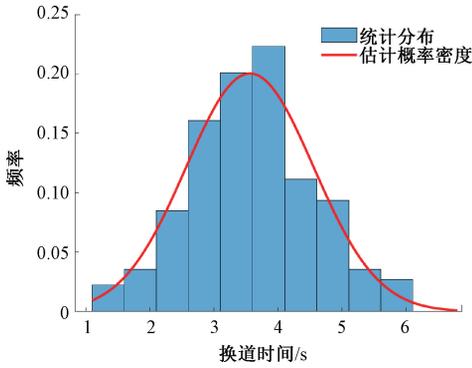


图 5 换道时间统计频率

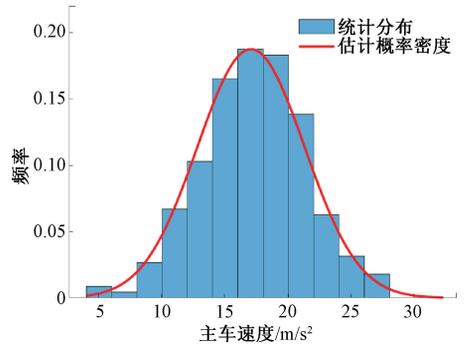


图 8 主车速度统计频率

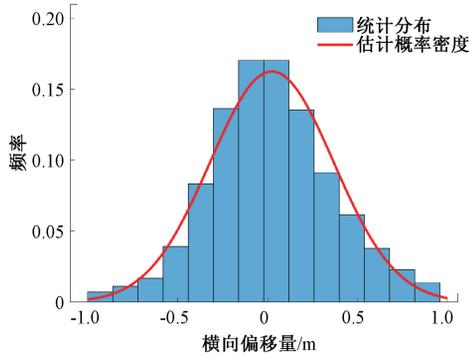


图 6 横向偏移量统计频率

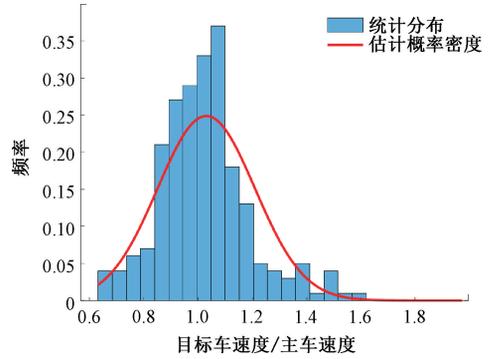


图 9 前车与主车速度之比统计频率

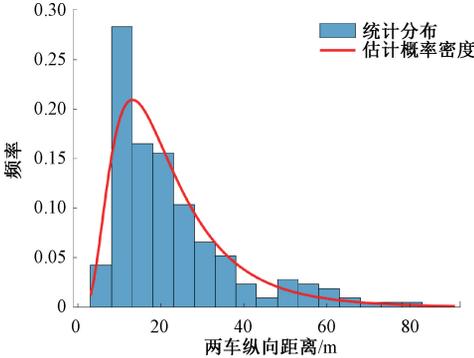


图 7 前车换道时两车纵向距离统计频率

表 3 中,按上述规则提取的前车与主车速度比的取值范围为 $[0.566\ 9, 1.493\ 7]$,为了减少无用场景的生成,前车的速度参数用前车与主车的速度比代替,当速度比大于 1 时(换道车辆速度大于主车速度),表示场景无风险。故最终选定的前车与主车速度比区间为 $[0.566\ 9, 0.9]$ 。

2 风险场景的自适应生成

通过上文对 NGSIM 数据集的处理,得到了场景参数分布范围和概率分布,本节需要在其基础上构建风险场景自适应生成及测试模型,整体场景生成及测试算法模型流程如图 10 所示。

表 3 场景参数取值范围和分布概率

	概率分布	取值范围	离散空间
换道时间	$X \sim N[3.554\ 5, 0.995\ 8^2]$	$[0.985\ 3, 6.123\ 7]$	$[1; 0.1; 6]$
横向偏移量	$X \sim N[0.024\ 6, 0.343\ 6^2]$	$[-0.861\ 9, 0.911\ 1]$	$[-0.9; 0.05; 0.9]$
纵向距离	$X \sim \text{LogN}[2.943, 0.601\ 4^2]$	$[4.020\ 4, 89.533\ 4]$	$[4; 1; 90]$
主车速度	$X \sim N[17.079\ 4, 4.257\ 7^2]$	$[6.094\ 5, 28.064\ 3]$	$[6; 0.5; 28]$
前车与主车速度比	$X \sim N[1.030\ 3, 0.179\ 6^2]$	$[0.566\ 9, 1.493\ 7]$ 截取后 $[0.566\ 9, 0.9]$	$[0.55; 0.01; 0.9]$

2.1 功能场景构建

首先构建功能场景。结合前文换道场景模型和被测车辆信息,完成对前车换道场景的场景生成。主车在长直三车道道路上行驶,前车要对主车行驶产生干扰。主车搭

载 AEBS 系统,前车搭载换道阻挡控制模型,通过场景参数矩阵 $[d_{before}, D, v_{rate}, v, t, d_{after}]$ 控制。主车预设路径为直线行驶,车速为 v 。场景构建结果如图 11 所示。

由遗传算法生成的场景参数矩阵对前车轨迹和速度

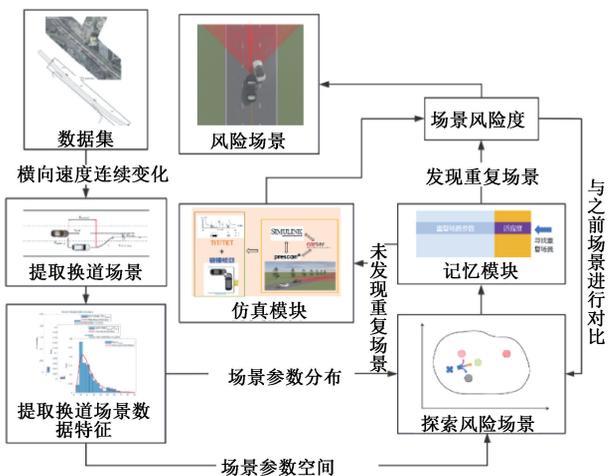


图10 场景自适应生成的自动驾驶测试方法流程



图11 Cut-In 场景构建结果

进行联合控制,主车速度由场景参数矩阵中 v 和 AEBS 系统联合控制。该流程中每个个体都是 1 个仿真场景,在生成高风险场景的过程中,同时完成该场景下辅助驾驶测试。记录每次测试中主车与前车的轨迹、速度、是否碰撞等关键参数,以便后期对场景完成回放和重复记录等工作,两车 Simulink 控制模型如图 12 所示。

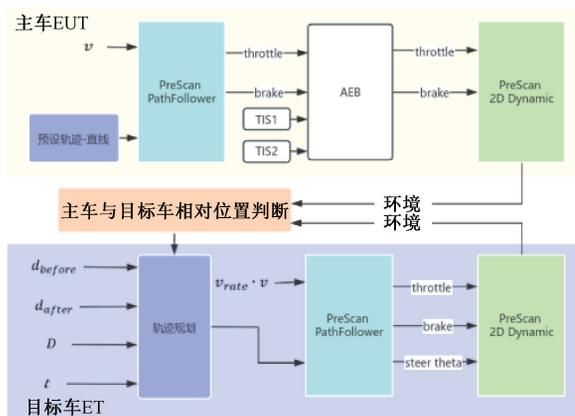


图12 基于 Simulink 平台的两车控制模型示意图

2.2 风险场景搜索过程

本文以遗传算法为基础,增加了重复场景记忆模块和场景约束模块,并对遗传算法中的搜索过程进行改进,使其针对风险场景的搜索更加高效。

1) 适应度函数

由于自适应生成方法属于在线生成方法,是结合实时

仿真的风险场景发掘方法,可以采用 TTC 改良指标 TIT ^[18] 来进行评价。 TIT (time integrated TTC) 指标使用驾驶员碰撞时间曲线的积分来表示安全水平。在仿真过程中会出现速度波动,导致 TTC 小于 0 或 TTC 分母为 0 (两车速度相同) 情况,一般采用 TTC^{-1} ^[19] 来规避这种情况。结合两种指标,采用 TTC^{-1} 来表示安全水平。同理 TTC^{-1*} 表示临界 TTC^{-1} 值。图 13 为某次实时仿真中 TTC^{-1} 示意图,此次仿真中①、③部分 (小于 TTC^{-1*} 部分) 表示主车处于安全范围,发生碰撞概率较小;②部分 (大于 TTC^{-1*} 部分) 表示主车处于危险范围,发生碰撞概率较大,用②部分积分 (区域面积) 表示 TIT^{-1} 的值。

$$TIT^{-1*} = \sum_{i=1}^N \int_0^T [TIT^* - TTC_i^{-1}(t)] dt \quad (1)$$

$$\forall 0 \leq TTC_i^{-1}(t) \leq TTC^{-1*} \quad (2)$$

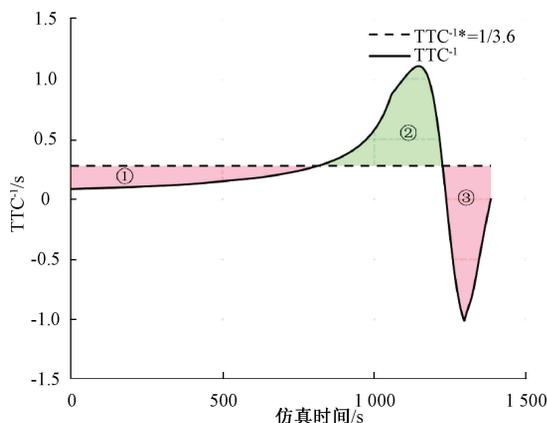


图13 某次实时仿真 TIT^{-1} 示意图

车辆不同碰撞情景时其碰撞方式和强度也各不相同。当碰撞不可避免时,自动驾驶算法也会采取一定措施来减缓碰撞造成的损害,所以不能将所有事故一概而论。碰撞过程较为复杂,PreScan 等商业软件难以模拟,如果联合 Ansys 等有限元分析软件仿真过程计算量过于庞大,不利于场景发掘。采用代理模型的方式对碰撞的损失进行量化,通过文献[20-22]可知,碰撞损失与速度呈正相关,本文通过相对速度范数来衡量碰撞强度。

$$S_{coll} = \|v - v_{rate} \cdot v\| \quad (3)$$

2) 场景搜索模块

场景搜索模块是基于传统遗传算法中种群进化方式进行改良,选择过程采用传统轮盘赌方式,场景风险度越高被选择参加下一次进化的概率越大。

交叉过程不会产生新的场景参数,是场景参数矩阵两两组合并随机交换相同种类参数的过程,此过程可以保证种群中优秀参数遗传给下一代。本文采用的交叉方式是双切点交叉。完整保留了父代的参数。

变异过程是拓展新的场景参数空间,保证场景参数的多样性,从而保证测试中的场景丰富度。变异点位随机生成,但为了保证向当前已知最优的方向即兴探索,对变异

方向进行约束。将当前个体(所需要变异操作的场景)风险度与最优个体(已生成所有场景中风险最高场景)风险度进行比较:如当前个体风险度小于最优个体风险度,变异方向大概率为最优个体方向(如图 14 黄色圆形所示),同时还有向其他方向变异的小概率,来防止局部最优解的出现;如当前个体风险度大于等于最优个体风险度,则表示当前个体为新的最优个体,下一代个体变异方向将向当前个体的四周均匀发散。变异过程如图 14 所示。

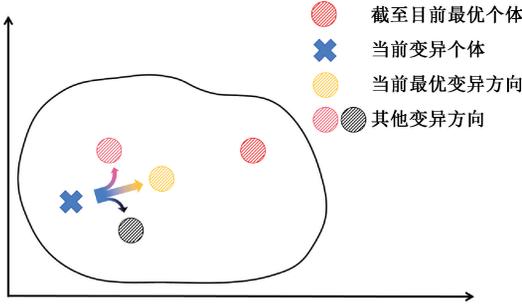


图 14 变异过程示意图

变异步长由 Beta 分布 $X \sim [\alpha, \beta]$ 决定, $\beta = 5, \alpha$ 随着迭代次数增加而增大, 表示个体变异前进更大步长的概率也会增加, 可以防止种群陷入局部最佳。

$$\alpha = 1 + 0.02Gen \quad (4)$$

3) 重复场景记忆模块

在场景搜索过程中采用实时仿真后的结果作为适应度计算的基准, 需要长时间的运算。在搜索高风险场景的过程中, 会遇到重复的场景, 重复场景记忆模块的作用是记录所有场景仿真的结果, 当判定为重复场景时, 直接通过查表方式从记忆模块中提取适应度, 而非重复仿真。此方法可以节约运算时间且不破坏种群的整体性。

4) 仿真时间

为了加快仿真速度, 提高计算效率, 仿真时间采用非定值, 通过场景矩阵计算生成。将换道过程看作匀速, 计算公式如下:

$$startTime = 0, endTime = \frac{d_{initial} - D}{(1 - v_{rate})v} + \frac{t}{2} + t_{con} \quad (5)$$

其中, t_{con} 表示前车侵入主车车道后仿真持续时间, 由于车辆期望速度要小于前车速度, AEBS 系统会导致 TTC^{-1} 呈现固定周期的波动(图 13 中的②和③为一周期)。从而导致 TTC^{-1} 在 TTC^{-1*} 附近波动, 计算 TIT^{-1} 时, 当仿真时间过长, 波动次数多, 导致 TIT^{-1} 变大; 仿真时间过短, ②的面积变小, 导致 TIT^{-1} 变小。为了保证仿真停止时间处于③周期内, t_{con} 设置为 3.5。

5) 场景约束

当纵向碰撞时间 $TTC_{longitudinal}$ 小于横向碰撞时间 $TTC_{lateral}$, 主车会在前车未完成变道时超越前车, 且不会发生碰撞, 纵向碰撞时间和横向碰撞时间通过如下公式计算。

$$TTC_{lateral} = \frac{\omega_R - \omega_{EUT}/2 - d_{before}t}{\omega_R - d_{before} + d_{after}} \quad (6)$$

$$TTC_{longitudinal} = \frac{D}{v \cdot (1 - v_{rate})} \quad (7)$$

式中: ω_R 为道路宽度, ω_{EUT} 为主车宽度, ω_{ET} 为前车宽度。

6) 其他参数设置

为了加快遗传算法寻找更危险场景, 并增加场景丰富度, 对场景参数矩阵的元素进行了分类, 根据其对场景风险的影响程度分为高影响参数、中影响参数和低影响参数。高影响参数为 D 和 v_{rate} , 中影响参数为 v 和 t , 低影响参数为 d_{after} 和 d_{before} 。对不同影响程度的参数施加不同的变异率, 分别为 0.25、1.7 和 0.8。变异概率和交叉概率分别定为 0.7 和 0.9。迭代次数为 200 次, 每代 20 个个体, 当连续 7 代未出现更优秀的个体仿真停止。

2.3 风险场景生成结果

经过迭代共生成 439 个场景, 本文定义发生碰撞的场景为高风险场景。其中两车碰撞的场景有 266 个, 本文定义这些场景为高风险场景。

通过仿真发现, 在第 57 个场景中首次观察到了两车的碰撞, 在第 59 个场景中观察到两车碰撞, 在第 60 个场景中观察到两车碰撞……。共观测到 266 个场景发生两车碰撞。整个仿真运行时间为 2.45 h, 进化过程如图 15 所示。通过多次运行测试算法, 结果指向两种不同的碰撞方式。第 1 种场景表现为换道时间短, 两车相对速度较大, 前车触发 AEBS 系统, 主车右前侧与前车左侧中段发生碰撞; 第 2 种场景则为换道时间稍长, 此时前车换道意图并不明确, AEBS 系统并未干预预驾驶, 导致前车侵入主车所在车道后依旧未采取制动措施, 前车左前侧与主车右侧中段发生碰撞。

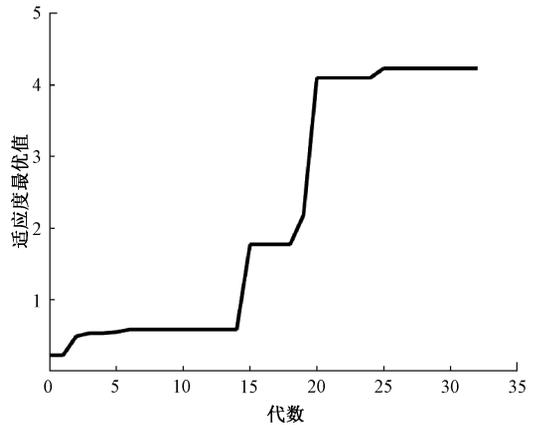


图 15 最大适应度曲线

2.4 基于风险场景搜索的优势

为了证明本文测试方法在生成高风险场景方面的优越性, 在相同的 PreScan 测试平台中使用组合测试、随机采样测试、穷举法和优化生成边缘场景法方法进行了场景生

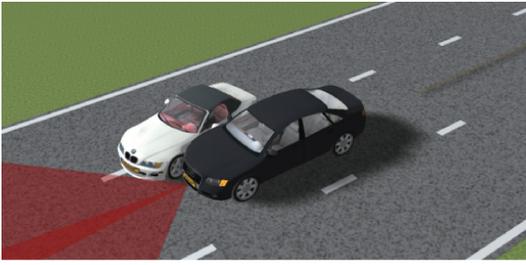


图 16 风险场景(碰撞时刻)示意图

成和自动驾驶测试,以前车换道场景模型为例,对不同方法高风险场景的生成结果对比分析:

多维度组合测试^[2]方法可以在满足覆盖度的情况下,大幅度减少测试场景数量。以本文所构建场景为例,参数空间与本文设置相同,需要进行 4 437 次实验,风险场景 138 个,一般场景 4 299 个,运行时间约为 29 h。

随机采样测试^[4,23]也是常用的测试方法,用于常规功能测试,测试数量由采样密度决定,缺点是包含大量的冗余低风险用例。在参数空间内依据场景出现概率进行随机抽样,定义生成 800 个场景,共生成风险场景 19 个,约占总场景的 0.022 5。

穷举法需要对 $1.444\ 7 \times 10^9$ 个场景进行仿真测试,通过随机采样测试和 PICT 方法的运行时间可以类比计算出穷举法需要约 1 107 年才可以运行完成。

通过经验得到适应度函数^[5,14]并采用遗传算法离线生成边缘场景,得到 2 000 个场景,其中 95 个场景重复,共生成 1 905 个有效场景,生成时间 47 s。筛选适应度较高的 1 000 个场景,通过仿真测试对其进行验证,运行时间 8 h,发现风险场景 347 个,此方法生成结果与适应度函数的制定关系较大,不合理的适应度函数并不能生成高风险场景。

5 种方法的运行时间和生成风险场景的比例参数如表 4 所示。

表 4 5 种方法运行时间与风险场景比例对比

方法	运行时间	风险场景比例
组合测试	约 29 h	0.031
随机采样测试	约 6 h	0.135
穷举法	约 1 107 年	—
优化生成边缘场景	约 8 h	0.347
本文方法	约 2.45 h	0.6

3 结 论

针对自动驾驶测试问题,本文提出了一种基于风险场景搜索的自动驾驶测试方法,利用公开数据集提取换道场景参数矩阵取值范围和概率分布,通过改良遗传算法中的搜索过程,添加记忆模块和针对自动驾驶场景的约束完成

对 AEBS 算法的仿真测试。研究发现:本文方法可以通过不断迭代发现算法漏洞,通过遗传不断提高场景 TIT^{-1} ,最终发掘出风险场景。出现风险场景后还在不断提高事故发生前的风险度,此方法对其他自动驾驶系统测试也具有指导意义。遗传算法每次迭代生成的个体都是一个独立场景,在迭代过程中完成了不同风险度场景的测试。通过算法共生成了 439 个场景,其中发生碰撞的场景有 266 个。多次运行本文场景生成及测试算法发现被测自动驾驶算法有两种失效方式。本文创新点在于将优化方法与在线测试结合起来,使用遗传算法与 PreScan 在线仿真测试相结合,通过遗传算法调用 PreScan 仿真模块,并将其仿真结果传输到遗传算法程序中并完成适应度计算形成闭环,解决了传统优化方法中适应度函数较为主观且不能描述行车过程的缺陷。该方法的技术难点在于如何通过遗传算法调用 PreScan,并对场景参数进行修改;如何将仿真结果转化为适应度函数来引导算法搜索生成新场景。在后续的研究中应增加更多的交通参与者,提升场景复杂度,达到更好的测试效果。

参考文献

- [1] HUANG W, WANG K, LV Y, et al. Autonomous vehicles testing methods review [C]. IEEE, 2016. 163-168.
- [2] 舒红,袁康,修海林,等.自动驾驶汽车基础测试场景构建研究(双语出版)[J].中国公路学报,2019,32(11): 245-254.
- [3] 朱宇,赵祥模,徐志刚,等.基于蒙特卡罗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,2022,25(3): 89-100.
- [4] YAN X, FENG S, SUN H, et al. Distributionally consistent simulation of naturalistic driving environment for autonomous vehicle testing [J]. Ithaca: Cornell University Library, 2021, DOI: 10.48550/arXiv.2101.02828.
- [5] BEGLEROVIC H, STOLZ M, HORN M. Testing of autonomous vehicles using surrogate models and stochastic optimization[C]. IEEE 20th International Conference on Intelligent Transportation Systems, 2017.
- [6] KLUCK F, ZIMMERMANN M, WOTAWA F, et al. Genetic algorithm-based test parameter optimization for adas system testing[C]. IEEE, 2019. 418-425.
- [7] 邓伟文,李江坤,任秉韬,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): 316-333.
- [8] ESHELMAN L J. The CHC adaptive search algorithm: How to have safe search when engaging in nontraditional genetic recombination[J]. Foundations

- of Genetic Algorithms, 1991:265-283.
- [9] SRINIVAS N, DEB K. Multiobjective optimization using nondominated sorting in genetic algorithms[J]. Evolutionary computation, 1994,2(3):221-248.
- [10] DEB K, PRATAP A, AGARWAL S, et al. A fast and elitist multiobjective genetic algorithm: NSGA-II[J]. IEEE Transactions on Evolutionary Computation, 2002, 6(2):182-197.
- [11] ROMANOVSKY A, TROUBITSYNA E, BITSCH F. Fitness functions for testing automated and autonomous driving systems [C]. International Conference on Computer Safety, Reliability, and Security, 2019.
- [12] FERRARA A, VECCHIO C. Collision avoidance strategies and coordinated control of passenger vehicles [J]. Nonlinear Dynamics, 2007,49(4):475-492.
- [13] 李春银. 基于 prescan 的自动驾驶测试场景生成及虚实结合测试系统构建[D]. 西安:长安大学, 2022.
- [14] 景荣荣, 吴兰, 张坤鹏. 基于生成对抗网络的自动驾驶交通场景生成[J]. 电子测量技术, 2023, 46(14): 146-154.
- [15] YAN X, ZOU Z, FENG S, et al. Learning naturalistic driving environment with statistical realism[J]. Nature Communications, 2023, 14(1):2037-2037.
- [16] LEE R, KOCHENDERFER M, MENGSHOEL O, et al. Adaptive stress testing of airborne collision avoidance systems[C]. 2015 IEEE/AIAA 34th Digital Avionics Systems Conference(DASC), 2015.
- [17] MULLINS, GALEN E, STANKIEWICZ, et al. Adaptive generation of challenging scenarios for testing and evaluation of autonomous vehicles[J]. The Journal of Systems and Software, 2018.
- [18] MINDERHOUD M M, BOVY P H. Extended time-to-collision measures for road traffic safety assessment[J]. Accid Anal Prev, 2001,33(1):89-97.
- [19] ZHU B, ZHANG P, ZHAO J, et al. Hazardous scenario enhanced generation for automated vehicle testing based on optimization searching method[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(7): 7321-7331.
- [20] 张培兴. 基于场景的自动驾驶汽车虚拟仿真加速测试与评价方法研究[D]. 吉林:吉林大学, 2023.
- [21] SONG Y, CHITTURI M V, NOYCE D A. Automated vehicle crash sequences: patterns and potential uses in safety testing[J]. Accident Analysis & Prevention, 2021, 153: 106017.
- [22] 李树歧. 基于碰撞前车辆状态的双车碰撞事故严重度评估模型的构建[D]. 西安:长安大学, 2023.
- [23] JUNIETZ P, WACHENFELD W, KLONECKI K, et al. Evaluation of different approaches to address safety validation of automated driving [C]. International Conference on Intelligent Transportation Systems(ITSC), 2018.

作者简介

丁浩天, 硕士研究生, 主要研究方向为车辆虚拟测试仿真技术。

E-mail: dinght1102@163.com

王国权(通信作者), 博士, 教授, 主要研究方向为车辆动力学, 车辆虚拟试验技术与无人车技术。

E-mail: wang.guoquan@bistu.edu.cn