

DOI:10.19651/j.cnki.emt.2210766

# 基于DRF优化采样的无人车轨迹规划方法<sup>\*</sup>

李研强 郑亚雯 张岱峰 李超 张超

(齐鲁工业大学(山东省科学院)山东省科学院自动化研究所 济南 250013)

**摘要:**针对城市道路场景下无人驾驶汽车最优轨迹生成算法存在的运行时间长、轨迹评价标准单一的问题,提出一种基于行车风险场优化采样区域的无人车轨迹规划方法。该方法通过改进的二维高斯分布函数分别建立静态障碍物和动态障碍物风险场模型,对道路中采样区域目标点的行车风险进行量化,通过卷积的方式选定行车风险较小区域的采样目标点生成最优轨迹。仿真结果表明,该优化方法在每个规划周期只选取部分采样目标点用于轨迹生成,提高了算法的运行效率,使得算法单帧运行时间均小于0.1 s。行车风险场的加入使得算法的采样区域更加符合驾驶人的行为习惯,提高了算法规划结果的拟人化程度,从而保证无人车具有较高的行驶效率。

**关键词:**无人驾驶汽车;轨迹规划;行车风险场;二维高斯分布;卷积选定采样

中图分类号:U461 文献标识码:A 国家标准学科分类代码:510.80

## Driverless vehicle trajectory planning method based on optimal sampling of DRF

Li Yanqiang Zheng Yawen Zhang Daifeng Li Chao Zhang Chao

(Institute of Automation Shandong Academy of Sciences, Qilu University of Technology (Shandong Academy of Sciences), Jinan 250013, China)

**Abstract:** In order to solve the problem of long running time of single frame and single trajectory evaluation criteria existing in the optimal trajectory generation algorithm of driverless vehicles in urban road scenarios, a driverless vehicle trajectory planning method based on driving risk field to optimize sampling area was proposed. In this method, static and dynamic obstacle risk field models were established respectively through two-dimensional Gaussian distribution to quantify the target point of the sampling area on road. The sampling target points in the areas with low driving risks were selected by convolution to generate the optimal trajectory. The simulation results show that this optimization method only selects part of the sampling target points for trajectory generation in each planning period, which improves the running efficiency of the algorithm and makes the running time of each frame of the algorithm less than 0.1 s. The addition of driving risk field makes the sampling area of algorithm more consistent with the drivers' behavior and habits, improves the degree of anthropomorphism of the algorithm planning results, and ensures the high driving efficiency of the driverless vehicle.

**Keywords:** driverless vehicle; trajectory planning; driving risk field; two-dimensional Gaussian distribution; convolution selected sampling

## 0 引言

无人驾驶<sup>[1]</sup>是集感知、决策、规划、控制于一体的车辆智能化技术,无人驾驶技术的发展能够实现车辆的自动驾驶或辅助驾驶。其中轨迹规划<sup>[2]</sup>是整个无人驾驶技术中体现车辆自主行驶安全水平和通行效率的关键技术之一。它接收来自感知环节的当前车辆状态信息和实时的周边环境

信息,结合决策环节给出的局部目标点信息,实时地规划未来一段时间内满足车辆动力学和运动学约束的安全、舒适、无碰撞的最优轨迹,并应用于车辆控制模块。

无人驾驶轨迹规划方法主要可以分为以下几种:基于图搜索法<sup>[3]</sup>、基于采样的方法、基于曲线差值法<sup>[4]</sup>、基于数值优化方法<sup>[5]</sup>及人工势场法等。图搜索算法是采用遍历离散状态空间来寻找从起始点到目标点的最低代价的路径。

收稿日期:2022-07-21

\*基金项目:国家自然科学基金(52072214)、山东省重大科技创新工程项目(2019JZZY010126)资助

虽然图搜索算法因其广度优先的特性,能够快速搜索到全局最优路径,但是生成的路径未考虑道路几何形状且曲率不连续,导致生成的轨迹难以直接应用于车辆执行环节。基于采样的方法<sup>[6]</sup>是对状态空间进行采样,进而根据初状态和目标状态生成可行路径,其中快速搜索随机树(rapidly-exploring random-tree, RRT)<sup>[7]</sup>是基于采样的路径规划方法中最常用的方法之一。RRT 算法能够快速有效地在空间中搜索路径,但由于该方法生成新节点过程中缺乏监督,导致收敛速度较慢,搜索的路径仅为可行路径而非优化后的路径,且依然存在路径曲率不连续的问题。赵超力等<sup>[8]</sup>提出了基于引力场引导的 RRT-connect 算法,在各搜索节点上叠加一个引力场引导节点以减少无效空间的搜索。Karaman 等<sup>[9]</sup>提出 RRT\* 算法,在每次迭代后局部更新搜索树以优化路径,提高了搜索效率,但是并未解决曲率不连续问题。人工势场法<sup>[10]</sup>(artificial potential field, APF)是在势能场理论作用下,使无人车在目标点的引力与障碍物产生的斥力的共同作用下求解可行路径。APF 算法虽结构简单、收敛速度较快但容易陷入局部最小解。胡丹丹等<sup>[11]</sup>中提出一种基于势能重构的改进人工势场法,可以跳出局部最小解。然而,APF 基于势能场理论,其势场分布具有各向同性,没有考虑到障碍物因速度改变引起的行车风险变化。基于曲线插值<sup>[12]</sup>和数值优化<sup>[13]</sup>方法是采用多项式构造路径,将轨迹规划问题看作最优化问题,并通过数值参数化求解轨迹最优解。Werling 等<sup>[14]</sup>提出了基于 Frenet 坐标系的无人车最优轨迹生成算法(optimal trajectory generation, OTG),通过 Frenet 坐标系将轨迹解耦,通过先采样,然后通过多项式生成轨迹,最后代价函数优化的方法生成最优轨迹,但是该算法需要在每个规划周期对目标状态和轨迹进行均匀采样,导致算法运行时间较长。为了解决上述问题,张立鹏等<sup>[15]</sup>提出了一种将采样区域划分为基本代价区和障碍代价区进而动态筛选采样点的轨迹规划方法。虽然提高了算法的运行速度,但最优轨迹的选取仅依靠代价函数对候选轨迹进行评估,没有从道路环境的宏观角度判断轨迹的合理性。

综上,本文基于前人的研究基础,针对 OTG 算法存在的运行时间长、轨迹评价标准单一的问题,提出一种结合行车风险场(driving risk field, DRF)进行采样区域优化的轨迹规划方法,主要贡献如下:

1) 基于改进的二维高斯分布概率函数建立风险场模型,对采样区域目标点的行车风险进行量化。量化了不同道路参与者因其自身属性产生的行车风险,更加准确地反映了道路行车风险的分布情况。

2) 通过卷积选定行车风险较小区域的采样目标点进行轨迹生成,降低了算法所需遍历的轨迹数目,使算法的运行时间明显减少。

3) 风险较小区域的选择间接地将所建立的风险场模型引入到轨迹寻优过程,使对轨迹的选定不再仅依赖传统的

代价函数,提高了算法决策结果的合理性。

## 1 Frenet 坐标系

无人车轨迹规划环节是连接感知和控制的重要桥梁,它接收来自感知环节的环境信息及高精度地图的全局路由信息,生成一条基于全局参考路径下的可行驶轨迹。本文采用基于 Frenet 坐标系下进行无人车轨迹规划。Frenet 坐标系的建立仅和参考线选取有关,与无人车位置无关。图 1 表示无人车在笛卡尔坐标系和 Frenet 坐标系下的相互转换关系。

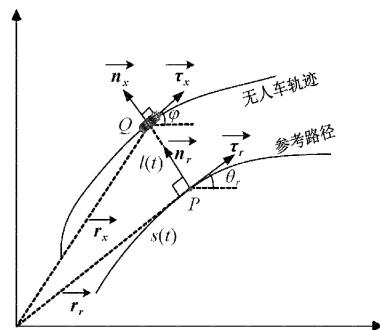


图 1 笛卡尔与 Frenet 坐标系相互转换关系

其中,  $\vec{n}_x$ 、 $\vec{t}_x$ 、 $\vec{n}_r$ 、 $\vec{t}_r$  均为单位向量, 无人车在笛卡尔坐标系的位置  $Q$  为  $\vec{r}_x = (x_x, y_x)$ , 在 Frenet 坐标系下表示为  $(s(t), l(t))$ ,  $s(t)$  表示纵向偏移,  $l(t)$  表示横向偏移。其中过点  $Q$  向参考线投影, 投影点  $P$  坐标为  $\vec{r}_r = (x_r, y_r)$ , 则无人车与投影点的偏移距离  $l$  表示为:

$$l = \sqrt{(x_x - x_r)^2 + (y_x - y_r)^2} \quad (1)$$

参考线在投影点处的切向角  $\theta_r$  通过计算得:

$$\theta_r = \arctan \frac{\dot{l}(t)}{\dot{s}(t)} \quad (2)$$

无人车的曲率  $k_r$  为:

$$k_r = \frac{\dot{s}(t)\dot{l}(t) - \dot{l}(t)\dot{s}(t)}{\sqrt{(\dot{s}(t)^2 + \dot{l}(t)^2)^3}} \quad (3)$$

无人车的航向角  $\varphi$  可以由式(1)~(3)计算得到:

$$\varphi = \theta_r + \arctan \frac{\dot{l}(t)}{1 - k_r} \quad (4)$$

根据文献[16]能够实现笛卡尔坐标系和 Frenet 坐标系相互转换,得到任意时刻道路交通参与者在 Frenet 坐标系及笛卡尔坐标系下的坐标信息。

## 2 基于改进的高斯分布函数的风险场建模

实际道路行驶中,车辆往往受机动车、行人、道路状况等因素的影响,且它们的行为状态具有不确定性,对无人车产生的行车风险就具有一定的未知性,这会严重影响无人驾驶车辆的行驶安全及通行效率,因此需要对道路中存在的行车风险进行量化评估。本文结合风险场理论参考二维高斯分布函数来描述单个风险源。点  $(x, y)$  处的二维高

斯分布为:

$$\left\{ \begin{array}{l} f(x,y) = (2\pi\sigma_1\sigma_2\sqrt{1-\rho^2})^{-1} e^{-\frac{q}{2(1-\rho^2)}} \\ q = \frac{(x-u_1)^2}{\sigma_1^2} - \frac{2\rho(x-u_1)(y-u_2)}{\sigma_1\sigma_2} + \frac{(y-u_2)^2}{\sigma_2^2} \end{array} \right. \quad (5)$$

式中:  $(u_1, u_2)$  表示风险源坐标;  $\sigma_1, \sigma_2$  分别表示数据沿  $x, y$  方向的标准差;  $\rho$  表示数据在  $x, y$  方向的相关程度。

将二维高斯分布的值看作与障碍物发生碰撞风险的概率,当无人车与障碍物发生碰撞时风险概率分布处于峰值。即场源坐标  $(u_1, u_2)$  对应的值  $f(u_1, u_2)$ ,且  $\sigma_1\sigma_2$  乘积的大小决定了风险分布的范围及峰值。 $\sigma_1\sigma_2$  乘积越小,则分布峰值就越大,风险分布范围越小。而从实际角度出发,车辆坐标与任何类型的障碍物坐标重叠时,必然会发生碰撞,且碰撞风险分布函数峰值应相同。因此直接采用二维高斯分布不符合实际。本文引入改进的二维高斯分布函数来建立风险分布模型,设计碰撞风险概率函数:

$$f(x,y) = \exp\left[-\frac{1}{2}\left(\frac{(x-u_x)^2}{\sigma_x^2} + \frac{(y-u_y)^2}{\sigma_y^2}\right)\right] \quad (6)$$

式中:  $(u_x, u_y)$  表示笛卡尔坐标系下的风险场场源坐标;  $(\sigma_x, \sigma_y)$  为车辆在笛卡尔坐标系下分别沿  $x$  轴和  $y$  轴的分布因子。

图 2 为二维高斯分布与改进二维高斯分布沿  $x$  轴的切面对比图。其中虚线表示典型高斯分布,实线表示改进分布,对比两个高斯分布可知,当  $\sigma_{11} < \sigma_{12}$  时,分布较“瘦高”,对应的峰值也更大。而对于改进分布,当  $\sigma_{x1} < \sigma_{x2}$  时对应的峰值都为 1。即改进的二维高斯分布函数是符合行车风险分布规律的。

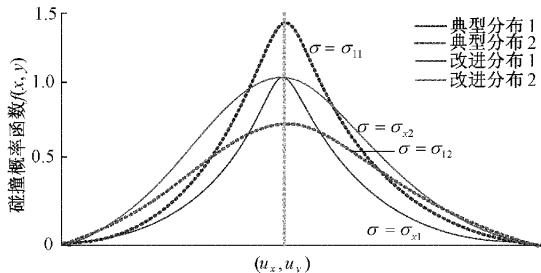


图 2 二维高斯分布与改进分布对比

由于车辆的类型、质量和速度都各不相同,所以产生的风险影响范围也会不尽相同,用分布因子  $\sigma_x, \sigma_y$  来描述风险分布范围。根据高斯分布的特点,分布因子越小,风险分布范围就越小。分布因子  $\sigma_x, \sigma_y$  可描述为:

$$\left\{ \begin{array}{l} \sigma_x = Z \left( \sqrt{\frac{\sum_{k=1}^N a_x^2 (-k\Delta t) \beta^k}{N}} + v_x^2 + \sigma_0 \right) \\ \sigma_y = Z \left( \sqrt{\frac{\sum_{k=1}^N a_y^2 (-k\Delta t) \beta^k}{N}} + v_y^2 + \sigma_0 \right) \end{array} \right. \quad (7)$$

式中:  $Z$  表示车辆尺寸,近似为车体的长宽高之和;  $N, \sigma_0$  表示待定常数;  $\Delta t$  表示采样间隔;  $a_x(-k\Delta t)$  表示移动车辆的加速度;  $\beta$  表示时间惩罚因子;  $(v_x, v_y)$  表示移动车辆分别沿  $x, y$  轴的速度分量。

## 2.1 静态障碍物建模

静态障碍物风险场模型,也称为静态场,主要表征可能与无人车(以下简称自车)发生碰撞的静止物体(本文特指停靠在路边的静止车辆)产生的行车风险。碰撞风险大小与交通参与者的质量、类型及运动状态有关。清华大学王建强等<sup>[7]</sup>提出了等效质量  $M$  来表示不同的交通参与者与无人车产生碰撞时造成的损害程度。在其他条件不变的前提下,虚拟质量越大,发生碰撞产生的碰撞损失就越大。本文将等效质量  $M$  引入计算风险场场强表达式中。

假定自车位置为  $(x_i, y_i)$ ,静态障碍车的位置为  $(x_j, y_j)$ ,则自车  $i$  受到来自场源障碍车  $j$  的静态场场强  $E_s$  为:

$$\left\{ \begin{array}{l} E_s(x, y) = GMf(x, y) \frac{r_{ij}}{|r_{ij}|} \\ r_{ij} = (x - x_j, y - y_j) \end{array} \right. \quad (8)$$

式中:  $G$  为固定常数;  $M$  为虚拟质量;  $f(x, y)$  为车辆在  $(x, y)$  处的风险分布模型;  $\frac{r_{ij}}{|r_{ij}|}$  为单位向量,表示静态场场强方向。

图 3 为质量  $m=1200 \text{ kg}$  的障碍车在  $(0, 0)$  处,风险分布因子  $\sigma_x = \sigma_y = 1$  产生的典型静态场。从图 3 可以看出,静态场分布具有各向同性,以障碍车坐标为中心,均匀向四周分布,且距离场源越远,风险场强就越小。

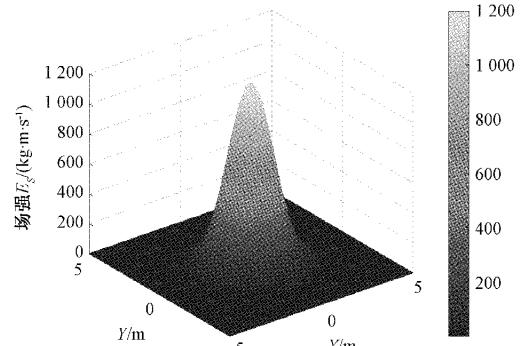


图 3 典型静态场

## 2.2 动态障碍物建模

移动障碍物风险场模型,也称为动态场,主要表征可能与自车发生碰撞的移动物体(本文特指移动车辆)产生的行车风险。自车受到移动障碍车产生的风险场强大小与二者的相对距离有关,距离越近,产生的风险越大。

假定自车位置为  $(x_i, y_i)$ ,动态障碍车的位置为  $(x_j, y_j)$ ,则自车  $i$  受到来自场源障碍车  $j$  的动态场场强  $E_d$  为:

$$\left\{ \begin{array}{l} E_d(x, y) = GMf(x, y) \frac{r_{ij}}{|r_{ij}|} \exp(k \cdot \cos\theta_j) \\ r_{ij} = (x - x_j, y - y_j) \end{array} \right. \quad (9)$$

式中:  $k$  是固定常数,  $\theta_j$  是两运动物体之间的夹角。

图 4 为质量  $m=1200 \text{ kg}$  的障碍车, 速度为  $20 \text{ km/h}$ , 沿  $x$  轴匀速行驶的移动障碍车在  $(0, 0)$  处, 风险分布因子  $\sigma_x = 4, \sigma_y = 1$  产生的典型动态场。从图 4 可以看出, 动态场分布具有各向异性, 车辆在其运动正方向产生的行车风险大于其负方向。

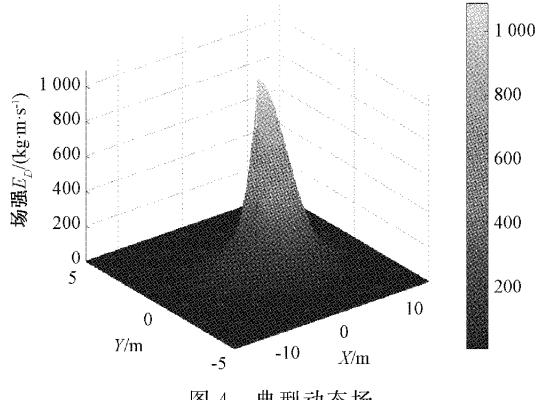


图 4 典型动态场

基于上述模型, 无人驾驶汽车的行车风险分布可视为静态场和动态场的共同作用如图 5 所示, 表达式为:

$$\mathbf{E} = \sum_{i=1}^N \mathbf{E}_{Di} + \sum_{j=1}^N \mathbf{E}_{Sj} \quad (10)$$

式中:  $\mathbf{E}$  为无人车在某一目标状态下受到的道路参与者的行车风险矢量和;  $\mathbf{E}_{Di}$  为单个移动障碍车产生的风险场强;  $\mathbf{E}_{Sj}$  为单个静态障碍车产生的风险场强。

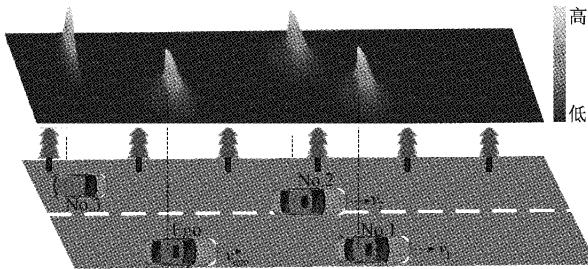


图 5 静态场和动态场合力场

通过建立静态场和动态场合力场模型, 可以将自行车在行驶过程中受道路参与者产生的行车风险进行统一量化。

### 3 低风险区域选定

#### 3.1 采样区域定义

OTG 算法的第一步就是进行横纵向采样得到足够多的目标点, 每个采样点都可以用 Frenet 坐标信息描述为  $(s_i, l_j), i = 1, 2, \dots, n_s, j = 1, 2, \dots, n_d$ 。 $n_s, n_d$  表示纵向、横向采样点个数。其中  $n_d = \frac{d_{\max} - d_{\min}}{\Delta d}$ ,  $d_{\max}, d_{\min}$  分别为横向采样最大距离和最小距离,  $\Delta d$  为横向采样间隔。另外, 为了避免无人车按规划轨迹行驶会超出道路边界, 本文对横向采样上下限进行约束, 即:

$$\begin{cases} d_{\max} = W_r - \frac{W}{2} \\ d_{\min} = -W_r + \frac{W}{2} \end{cases} \quad (11)$$

式中:  $W_r$  表示车道宽度,  $W$  表示自行车宽。纵向运动规划也称速度规划, 即对速度进行采样, 假定当前车速为  $v_{temp}$ , 轨迹规划的最大预测时间为  $t_{pre}$ , 车辆最大加速度和最小加速度分别为  $a_{\max}, a_{\min}$ , 则纵向采样速度上下限  $v_{up}$ 、 $v_{lp}$  为:

$$\begin{cases} v_{up} = v_{temp} + a_{\max} t_{pre} \\ v_{lp} = v_{temp} - a_{\min} t_{pre} \end{cases} \quad (12)$$

#### 3.2 低风险区域的选择策略

由于道路边界也存在着碰撞风险, 无人车因障碍车与道路边界风险的共同约束沿当前车道继续向前行驶, 导致陷入局部最小。图 6 表示局部最小场景下采样目标点的风险分布, 实线方框表示无人车 Ego, 虚线方框表示障碍车, 无人车在 OTG 算法的作用下会被两辆障碍车和道路边界产生的碰撞风险包围无法脱离。为了避免碰撞, 无人车开始减速甚至连续换道, 导致行驶效率较低。且 OTG 算法需要对均匀采样生成的全部采样点进行轨迹生成和代价评估, 造成算法计算时间代价较大。

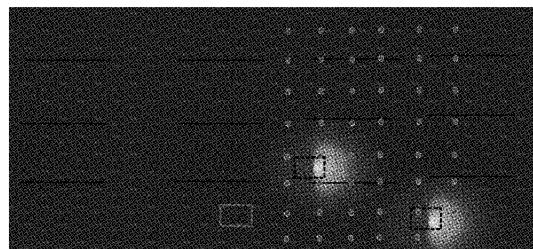


图 6 采样目标点的风险分布

为了解决上述问题, 本文通过低风险区域来筛选采样点, 在轨迹生成之前只需要考虑低风险区域的采样目标点即可。低风险区域的选择需要先计算各个采样目标点的行车风险值  $E$ , 将其组成风险矩阵  $RM$ , 通过卷积的方式对风险矩阵的采样目标点进行筛选, 选择卷积最优值对应的区域(如图中阴影部分所示)作为低风险区域。卷积选定低风险区域过程如图 7 所示。

低风险区域筛选采样点的详细算法流程如下:

1) 输入无人车的当前状态信息、预测时间, 按照预先定义好的采样间隔进行横纵向采样得到目标点状态  $[s_{n1}, s_{n2}, \dots, s_{ns}], [l_{n1}, l_{n2}, \dots, l_{ns}]$ ;

2) 分别使用 5 次、4 次多项式得到各个采样点的位置信息, 利用式 (6)~(10) 的场强量化公式量化这些采样目标点得到风险矩阵  $RM$ ,  $RM$  大小为  $n_d \times n_s$ ;

3) 使用  $m \times n$  的卷积核进行目标风险区区域的最优寻找, 将得到卷积结果为  $(n_d - m + 1) \times (n_s - n + 1)$  大小的

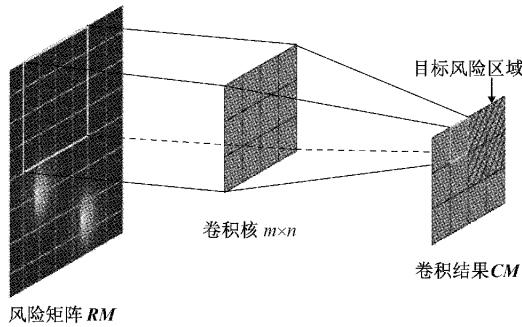


图7 卷积寻优图

矩阵  $CM$  作为风险估值,对卷积矩阵进行逆序遍历,选择每列最小值对应的区域组成低风险区域,该区域的采样目标点用于生成轨迹。卷积找寻低风险区域的伪代码如算法 1 所示。

#### 算法 1 卷积寻优伪代码

```

输入  $RM, CM$ 
输出 最优轨迹
for  $i = 1 : n_d - m + 1$ 
     $RS = sort(CM(:, n_d - m + 1 - (i - 1)))$ 
    for  $j = 1 : n_c - n + 1$ 
        # 返回 RS 中第 j 个值在 CM 中所在的行号 r 和列号 c
         $s\_label = [s_r, \dots, s_{r+n-1}]$ 
         $d\_label = [l_c, \dots, l_{c+m-1}]$ 
        # 轨迹检查及寻优都在 s_label, l_label 组成的期望风险区域中进行
        if 存在最优轨迹
            # 输出最优轨迹
            break
        end
    end
end

```

通过卷积的方式得到期望风险区域的同时,该区域的采样点将会被筛选出来用于寻找最优轨迹。

### 3.3 轨迹生成

确定了低风险区域以后,此区域内的采样目标点用于横纵向轨迹的生成,然后再耦合得到备选轨迹序列。用 5 次多项式表示横纵向轨迹,公式表示如下:

$$\begin{cases} l(t) = c_{l0} + c_{l1}t + c_{l2}t^2 + c_{l3}t^3 + c_{l4}t^4 + c_{l5}t^5 \\ s(t) = c_{s0} + c_{s1}t + c_{s2}t^2 + c_{s3}t^3 + c_{s4}t^4 + c_{s5}t^5 \end{cases} \quad (13)$$

式中:  $l(t)$ 、 $s(t)$  分别表示横向、纵向轨迹的 5 次多项式,其中,  $c_{l0}$ 、 $c_{l1}$ 、 $c_{l2}$ 、 $c_{l3}$ 、 $c_{l4}$  和  $c_{l5}$  表示横向 5 次多项式的系数;  $c_{s0}$ 、 $c_{s1}$ 、 $c_{s2}$ 、 $c_{s3}$ 、 $c_{s4}$  和  $c_{s5}$  表示纵向 5 次多项式的系数。

### 4 路径可行性检查及寻优

确定低风险区域后,轨迹检查和寻优都在此区域内进

行。轨迹检查主要包括曲率检查和碰撞检查。按照式(3)计算轨迹的曲率,判断是否超过最大曲率  $k_{r\max}$ 。碰撞检查规则是分别计算无人车到障碍车的横向和纵向距离,比较其与横纵向碰撞阈值的关系,大于碰撞阈值的轨迹会发生碰撞。将不满足曲率检查和碰撞检查的轨迹从备选轨迹中剔除,其余的可行性候选轨迹按照设计好的代价函数,计算每一条轨迹的代价值,最小化代价函数的轨迹则作为最优轨迹输出。代价函数分为横向和纵向,其中横向、纵向代价函数  $C_l$ 、 $C_s$ , 分别为:

$$C_l = k_{jerk} \int_{t_s}^{t_e} \ddot{l}(t)^2 dt + k_l |l_{center} - l_e| \quad (14)$$

$$C_s = k_{jerk} \int_{t_s}^{t_e} \ddot{s}(t)^2 dt + k_s |v_{tar} - \dot{s}_e| \quad (15)$$

总代价函数为横向和纵向的加权和:

$$C = K_{LAT}C_l + K_{LON}C_s \quad (16)$$

代价函数中用横纵向加速度的导数即 jerk 的平方来衡量轨迹舒适性,  $t_s$ 、 $t_e$  分别为规划的起始时间和终止时间,  $|l_{center} - l_e|$  项用来惩罚轨迹偏离车道中心线的程度,其中  $l_{center}$  表示车道中心线的位置,  $l_e$  表示路径末端采样点的位置,  $|v_{tar} - \dot{s}_e|$  项表示当前速度和目标保持速度的差值,用于保证行驶效率。其中,  $v_{tar}$  表示目标保持速度,  $\dot{s}_e$  表示末端采样点的对应的速度值。 $k_{jerk}$ 、 $k_l$ 、 $k_s$ 、 $K_{LAT}$  和  $K_{LON}$  分别为各自对应项的权重。

### 5 仿真分析

为验证本文改进算法的有效性和可行性,在 CPU 为 Intel(R) Core(TM) i7-6800K, 4.00 GHz, RAM 为 32 G 的 Windows 工控机上搭建 MATLAB/Simulink 仿真平台分别进行软件在环仿真测试和实车仿真测试。

#### 5.1 软件在环仿真测试

仿真实验选取了济南燕子山路(燕子山路为双向 8 车道,车道总宽 30 m,限速 60 km/h)的部分单向 4 车道路段搭建了直道仿真测试场景,如图 8 所示,横坐标表示纵向位移  $s$ ,纵坐标代表横向位移  $l$ 。本文选取的行车车速均符合实际道路标准行驶速度。其中 Ego 方块车速为 54 km/h,障碍车 1 和 2 方块均沿  $x$  轴匀速行驶,速度分别为 28、36 km/h。

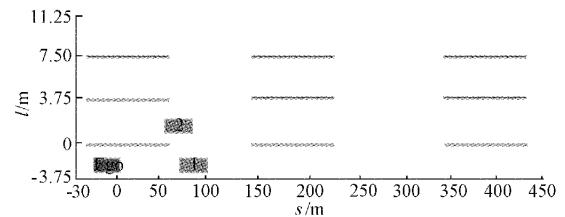


图8 软件在环仿真测试场景图

仿真规划参数如表 1 所示。

无人车 Ego 在该工况各阶段的规划结果如图 9 和 10 所示,其中短虚线表示可行轨迹,长虚线表示不满足约束轨

表 1 轨迹规划参数表

参数	数值
车道宽度 $W_r/m$	3.75
车长 $L/m$	4.7
车宽 $W/m$	1.8
车高 $H/m$	1.5
道路最大曲率 $k_{r\max}$	5
目标车速 $v_{target}$	54
横向碰撞阈值 $l_{\max}$	5
纵向碰撞阈值 $s_{\max}$	2
最大预测时间 $t_{pre}$	4
时间采样间隔 $\Delta t/s$	0.1
横向采样间隔 $\Delta d/m$	0.6
纵向采样个数 $n_s$	10
最大加速度 $a_{\max}/g$	2
最小加速度 $a_{\min}/g$	-3
权重 $k_j$	0.1
权重 $k_d$	0.7
权重 $k_s$	2
权重 $K_{LAT}$	1
权重 $K_{LON}$	1

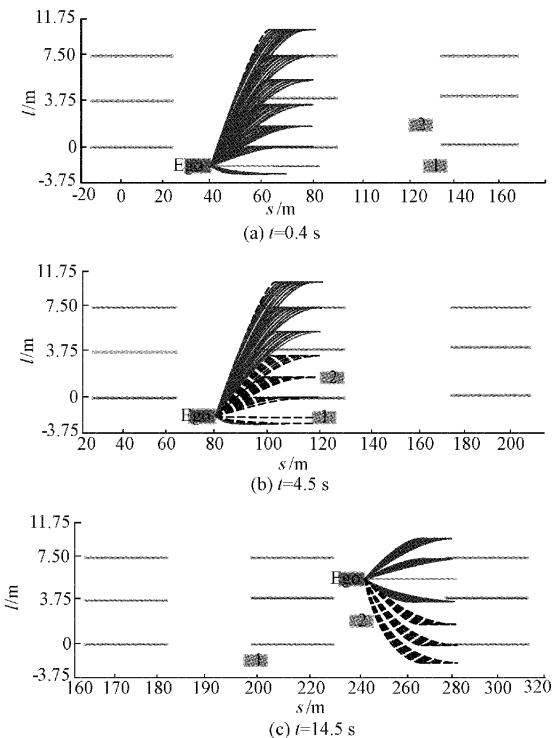


图 9 OTG 算法仿真结果

迹, 实线表示最优轨迹。图 9 表示 OTG 算法的仿真结果, 在仿真时间  $t = 0.4$  s 时, Ego 车沿当前车道中心线行驶;  $t = 4.5$  s 时, Ego 车为躲避障碍车 1 开始向左减速变道至

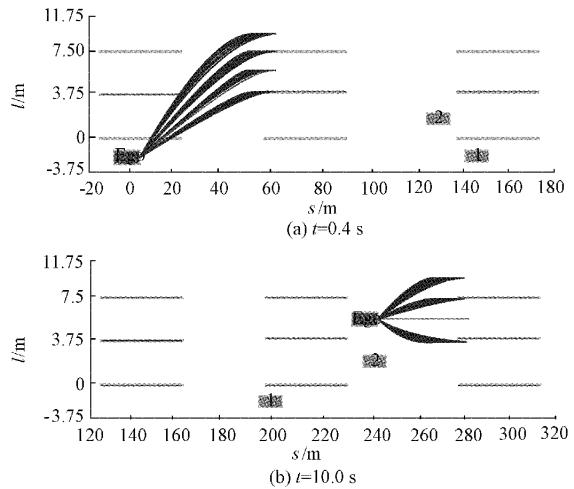


图 10 算法优化后的仿真结果

第 2 车道,紧接着为躲避障碍车 2 继续换道至第 3 车道;  $t = 14.5$  s 时, Ego 避障变道完成回归车道中心线继续向前行驶。图 10 为引入风险场筛选采样点的仿真结果, Ego 车在仿真开始  $t = 0.4$  s 时就选择向风险较低的第 3 车道变道行驶,  $t = 10.0$  s 时变道完成回归车道中心线继续向前行驶。

为了能定量地表示本文改进算法的优越性, 分别选取不同的横向采样间隔, 在相同的采样周期内, 对比 OTG 算法和本文改进算法的采样点数量, 对比结果如表 2 所示。

表 2 两种算法相同时段内采样点数量对比

采样 间隔 $\Delta d$	OTG 算法		本文改进算法	
	横向采样 点数	纵向采样 点数	横向采样 点数	纵向采样 点数
			点数	点数
0.6	25	10	12	6
0.45	33	10	16	8

通过对比, 通过卷积选定行车风险较小区域的采样点的方法, 轨迹数量存在明显减少现象, 相同场景进行密集采样前提下, 本文提出的改进算法相较于 OTG 算法, 可以降低算法所需遍历的轨迹数目, 使算法的运行时间明显减少。

工况中 Ego 车的横向位置-时间曲线如图 11 所示, 其中, 虚线表示 OTG 算法, 实线表示本文改进方法。OTG 算法在规划一开始受 *jerk* 的约束, Ego 车沿当前车道保持直行, 直到沿当前车道行驶的轨迹不满足约束, Ego 车为避免碰撞开始减速并连续向左变道。而本文改进算法从一开始就选择行车风险较小区域的采样目标点进行轨迹生成, 启发 Ego 车提前向左变至安全车道, 可在保证行驶安全的同时辅助 Ego 车做出合理的拟人化决策。

进一步地, 得到两种算法的纵向速度-时间曲线如图 12 所示, 虚线表示 OTG 算法, 实线表示本文改进方法。OTG 算法行驶一段时间开始减速避障, 而本文方法可以使 Ego

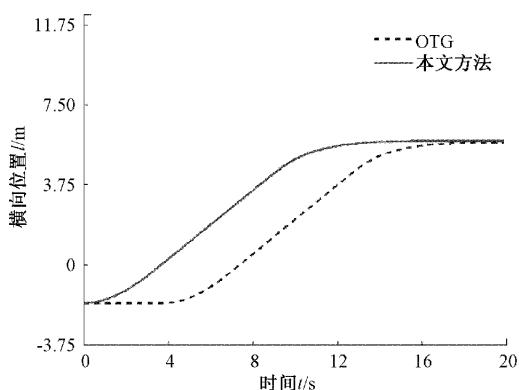


图 11 横向位置-时间关系

车一直以较高的速度行驶,再次验证了采用低风险区域对采样点进行筛选能够提高无人车辨识其他障碍车风险的能力,保证行驶高效性。

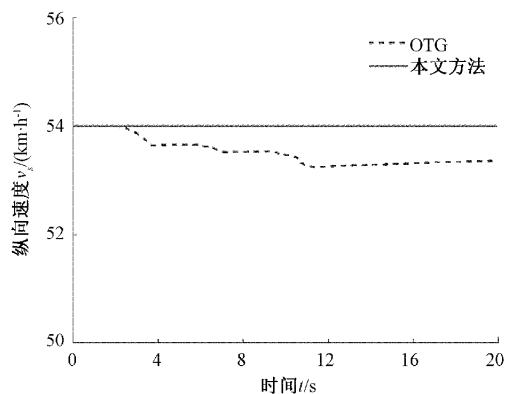


图 12 纵向速度-时间关系

轨迹规划算法的单帧运算时间如图 13 所示,虚线表示 OTG 算法,实线表示本文改进方法,且横坐标代表规划帧数,纵坐标代表 CPU 单帧运算耗时。仿真结果表明,OTG 算法单步运算耗时基本大于 0.2 s,而所提优化方法的单帧运算耗时均小于 0.1 s,耗时远小于 OTG。即相同采样间隔,所提出的通过 DRF 优化采样区域的方法可以有效降低算法的运行时间。

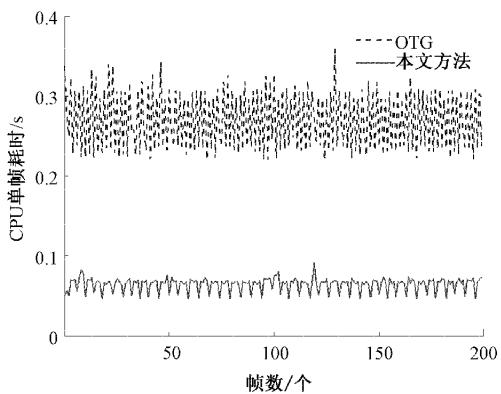


图 13 CPU 单帧运算耗时

## 5.2 实车仿真测试

为验证本改进算法对真实场景的有效性,搭建了一个实车仿真模型进行实车仿真测试验证。图 14 为同一时刻两种算法的实车仿真场景 3D 显示对比效果图。

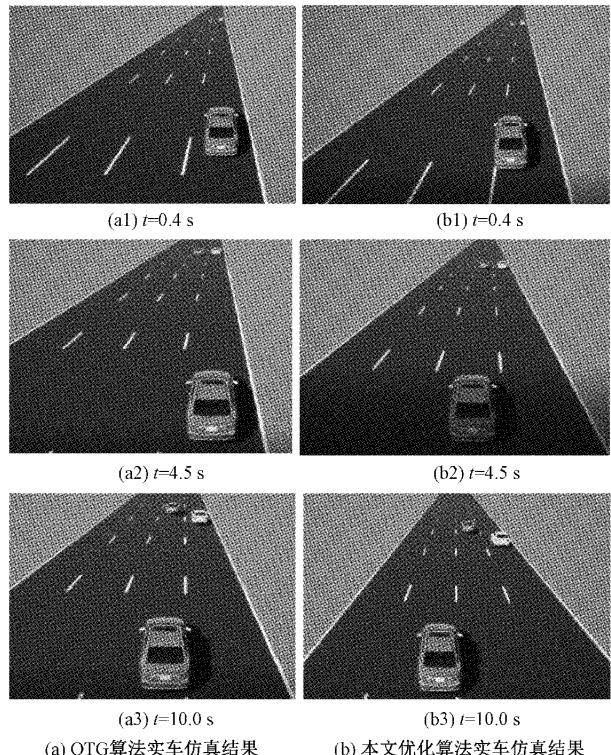


图 14 同一时刻两种算法实车仿真对比

由图 14 可以看出,在同一时刻,本文改进算法从仿真一开始采取提前变道的方式,优先选择了行车风险较小区域的采样点进行轨迹生成,避免了减速避障。由于将所建立的风险场模型间接地引入到轨迹寻优过程,使对轨迹的选定不再仅依赖传统的代价函数,不仅提高了算法决策结果的合理性,还保证了无人车具有较高的行驶效率。

## 6 结 论

针对 OTG 算法存在的运行时间长、轨迹评价标准单一的问题,本文提出一种考虑行车风险优化采样区域的轨迹规划方法。基于改进的二维高斯分布函数建立风险场模型并应用于无人车的轨迹规划,利用卷积的方式确定行车风险较小区域,进而对采样目标点进行部分选取。与 OTG 算法相比,所提优化方法选取部分采样目标点进行轨迹生成,能够减少轨迹检查的数量,有效降低算法的运行时间,还能辅助无人车做出合理的拟人化决策行为,避免陷入局部最优,从而保证无人车具有较高的行驶效率。此外,本文仅在直道场景验证了该优化方法的可行性,后续将进一步验证该优化方法在复杂道路场景下的应用。

## 参考文献

- [1] 李克强,戴一凡,李升波,等.智能网联汽车(ICV)技术

- 的发展现状及趋势[J]. 汽车安全与节能学报, 2017, 8(1):1-14.
- [2] 郑开瑜. 结构化环境下自主车辆的局部轨迹规划[D]. 杭州:浙江大学, 2020.
- [3] 卞强,孙齐,童余德.一种新的改进 A\* 算法无人机三维路径规划[J]. 武汉理工大学学报,2022,44(7):80-88.
- [4] 张宏宏,甘旭升,李双峰,等.复杂低空环境下考虑区域风险评估的无人机航路规划[J]. 仪器仪表学报,2021, 42(1):257-266.
- [5] 赵洋,高立,何羚,等.一种基于三次样条插值法的时基误差校正方法[J]. 国外电子测量技术, 2017, 36(8): 30-33.
- [6] 韩小健,赵伟强,陈立军,等.基于区域采样随机树的客车局部路径规划算法[J]. 吉林大学学报(工学版), 2019,49(5):1428-1440.
- [7] 王圣懿,黄劲松.基于先验概率分布改进的 RRT 车辆运动规划算法[J]. 导航定位学报,2022,10(2):85-92.
- [8] 赵超力,马行,张春涛,等. 基于引力场引导的 RRT-connect 路径规划算法 [J]. 电子测量技术, 2021, 44(22): 44-49.
- [9] KARAMAN S, FRAZZOLI E. Optimal kinodynamic motion planning using incremental sampling-based methods[C]. IEEE 2010 49th IEEE Conference on Decision and Control(CDC), 2010: 7681-7687.
- [10] 翟丽,张雪莹,张闲,等. 基于势场法的无人车局部动态避障路径规划算法[J]. 北京理工大学学报, 2022, 42(7): 696-705.
- [11] 胡丹丹, 张琪. 基于 PER-APF 算法的无人驾驶汽车换道轨迹规划[J]. 计算机测量与控制, 2022, 30(6): 229-234,241.
- [12] ZIEGLER J, BENDER P, DANG T, et al. Trajectory planning for Bertha-A local, continuous method[C]. Proceedings of the 2014 IEEE Intelligent Vehicles Symposium Proceedings, 2014:450-457.
- [13] 朱英杰,李建市,冯明月,等. 基于数值优化的智能车自主泊车路径规划算法[J]. 军事交通学院学报,2019, 21(11): 84-89.
- [14] WERLING M, ZIEGLER J, KAMMEL S, et al. Optimal trajectory generation for dynamic street scenarios in a frenet frame[C]. 2010 IEEE International Conference on Robotics and Automation(ICRA), 2010:987-993.
- [15] 张利鹏,苏泰,严勇. 基于采样区域优化的智能车辆轨迹规划方法[J]. 机械工程学报,2022,(14):276-287.
- [16] 魏民祥,滕德成,吴树凡. 基于 Frenet 坐标系的自动驾驶轨迹规划与优化算法[J]. 控制与决策,2021,36(4): 815-824.
- [17] 王建强,吴剑,李洋. 基于人-车-路协同的行车风险场概念、原理及建模[J]. 中国公路学报, 2016, 29 (1): 105-114.

### 作者简介

李研强(通信作者),研究员,研究生导师,主要研究方向为智能网联/无人驾驶算法研究。

E-mail: liyq@sdas.org

郑亚雯,硕士研究生,主要研究方向为无人驾驶轨迹规划。

E-mail: kzgczyw@163.com

张岱峰,助理研究员,主要研究方向为无人系统自主控制。

E-mail: zdfskh@163.com

李超,助理研究员,主要研究方向为无人车自主导航与定位。

E-mail: 1129267324@qq.com

张超,研究实习员,主要研究方向为无人车控制。

E-mail: zhangchao@sadas.org