

DOI: 10.13382/j.jemi.B2508484

# 基于虚拟障碍物决策的自适应两阶段轨迹规划方法<sup>\*</sup>

张俊豪  陶贤露  潘树国  高  旺  薛佳慧  
(东南大学仪器科学与工程学院  综合时空网络与装备技术全国重点实验室  南京  210096)

**摘  要:**针对传统轨迹规划算法在狭长空间规划成功率低、自适应程度差等问题,提出一种基于虚拟障碍物决策的自适应两阶段轨迹规划方法。首先,通过动态规划和二次规划完成无人车辆的路径规划和速度规划;其次,提出了一种自适应聚集采样策略解决了狭长空间较难通过的问题;最后,构建了一种基于随机森林的虚拟障碍物决策模型提升了无人车辆在不同会车情况决策的合理性。在 Carla(car learning to act) 仿真平台的结果表明,相比于传统方法,该方法在狭窄区域的静态多障碍物避障时路径长度、路径曲率分别降低了 2.4%、85.6%,规划成功率、安全性及其稳定性分别提高了约 20%、20.6%和 44.9%;在狭窄区域的动态多障碍物避障时路径长度、路径曲率分别降低了 8.3%、76.4%,规划成功率、安全性及其稳定性分别提高了约 36%、78.2%和 45.3%。最后,将方法部署到实际无人车辆中,在狭长的走廊场景设置障碍物进行测试,验证了方法的有效性。

**关键词:** 轨迹规划;自适应聚集采样策略;动态规划;二次规划;随机森林;Carla 仿真

**中图分类号:** TP242;TN96      **文献标识码:** A      **国家标准学科分类代码:** 460.40

## Adaptive two-stage trajectory planning method based on virtual obstacle decision-making

Zhang Junhao  Tao Xianlu  Pan Shuguo  Gao Wang  Xue Jiahui  
(State Key Laboratory of comprehensive PNT Network and Equipment Technology, School of Instrument Science and Engineering, Southeast University, Nanjing 210096, China)

**Abstract:**To address the limitations of traditional trajectory planning algorithms in confined spaces, such as low planning success rates, poor adaptability, and deviations from human driving habits, this paper proposes an adaptive two-stage trajectory planning algorithm integrated with virtual obstacle decision-making. The first stage combines dynamic programming and quadratic programming to achieve path planning and velocity optimization for autonomous vehicles. Subsequently, an adaptive aggregation sampling strategy is introduced to resolve navigation challenges in narrow environments. Finally, a random forest-based virtual obstacle decision model is developed to enhance decision-making rationality under diverse vehicle interaction scenarios. The results on the simulation platform Carla show that, compared with the traditional method, the path length and path curvature of the proposed method are reduced by 2.4% and 85.6% respectively, and the success rate of planning, safety and stability are improved by about 20%, 20.6% and 44.9% respectively in the static multi-obstacle avoidance in narrow areas. In the dynamic multi-obstacle avoidance in narrow areas, the path length and path curvature are reduced by 8.3% and 76.4%, respectively, and the planning success rate, safety and stability are improved by about 36%, 78.2% and 45.3%, respectively. Finally, the method was deployed to the actual unmanned vehicle, and the obstacles were set up in the narrow and long corridor scene for testing, which verified the effectiveness of the method.

**Keywords:** trajectory planning; adaptive aggregation sampling strategy; dynamic programming; quadratic programming; random forest; Carla simulation

## 0 引言

随着人工智能、电子通信等高新技术的迅猛发展,无人驾驶技术在全球范围内取得了显著的进步和成果。轨迹规划技术作为无人驾驶的重要技术组成,不仅是保障车辆安全行驶的核心,还决定了其能否高效到达目的地。轨迹规划的任务在于当无人车辆在行驶过程中遇到障碍物后规划一条安全、无碰撞的轨迹,这条轨迹包含位置、速度、时间、加速度等信息,便于控制模块进行控制。典型方法包括基于采样的方法、基于优化的方法、基于搜索的方法和基于几何曲线的方法<sup>[1]</sup>。在实际应用中,由于较低的计算复杂度和较高的灵活性,先采样、后优化的两阶段轨迹规划方法在智能驾驶领域备受关注<sup>[2]</sup>。

近年来,许多学者也提出了轨迹规划相关的方法。文献[3]提出了一种拟水流算法,通过拟水流避障算法和拟病毒算法进行避障,减少了寻路时间;文献[4]考虑了车辆动力学约束和周围车辆的运动信息以及安全距离,提出了一种基于5次多项式的线性规划轨迹曲线模型,以实现更加高效和安全的换道操作;文献[5]通过结合先验知识和运动学约束在速度规划空间进行自适应采样,使用动态规划算法计算最低代价路径并构建二次规划问题进一步优化此路径;文献[6]提出一种融合改进人类学习优化算法和动态窗口算法的路径规划算法,实现动态避障;文献[7]提出了一种改进的模型预测控制(model predict control, MPC)轨迹规划方法,用于自动驾驶车辆在不确定环境中的安全行驶;文献[8]考虑了道路摩擦和车辆速度对自动驾驶车辆的影响,同时兼顾了行驶安全和乘客舒适性,并通过构建七阶多项式函数来确保规划轨迹的连续性;文献[9]提出了一种基于车辆底盘全局动力学的轨迹规划方法,旨在解决现有方法在考虑车辆动力学高非线性时可能引起的操控不稳定问题;文献[10]结合了图搜索法和凸优化技术,能够在存在多边形障碍的环境中为动态系统规划出时间最优、距离最优和能量最优的轨迹。

现有的算法大多聚焦于宽敞的马路场景,然而在现实中常常会有狭长的道路和空间,例如地下停车场、巷道等,这些场景同样也需要无人车辆的应用,而对于这些场景轨迹规划的研究还较少。另外,在决策方面,轻决策方法占据主流,然而轻决策方法在一些场景下并不符合人类的驾驶习惯。因此,本文针对狭长空间无人车辆轨迹规划系统,提出一种基于虚拟障碍物决策的自适应两阶段轨迹规划方法。本文基于先采样、后优化的思想,首先,采用动态规划和二次规划完成对无人车辆的路径规划和速度规划;其次,在采样阶段提出了一种自适应聚集采样策略,能够使得规划器在狭窄路段的采样更加聚集

于可行行驶区域;然后,构建了一种基于随机森林的虚拟障碍物决策模型,使得规划器能够在无人车辆遇到不同的会车情况自适应做出合适的决策,例如超车、跟车、停车避让等。

## 1 两阶段轨迹规划的基本原理

本文所用两阶段轨迹规划方法分为采样和优化两个阶段,即首先在 Frenet 坐标系下进行采样,再通过动态规划和二次规划完成对轨迹的进一步优化。

### 1.1 Frenet 坐标系

面对结构化道路,局部规划的空间首先会受到车道形状和范围的约束,采用笛卡尔空间对车辆行驶状态进行表达,规划任务会十分复杂,采用 Frenet 坐标系进行表达,相对会比较简单<sup>[11]</sup>。Frenet 坐标系是一种运动轨迹规划坐标系,被广泛应用于汽车自动驾驶领域<sup>[12]</sup>。如图1所示,Frenet 坐标系以参考线和垂直于参考线的方向作为纵轴和横轴。这种做法用车辆偏离参考线的距离( $l$ 轴)和沿参考线方向行驶的距离( $s$ 轴)来描述车辆的位置,能够忽略道路曲率的影响,使得描述更加清晰明了,也有利于后续的轨迹规划。




图1 笛卡尔坐标系和 Frenet 坐标系对比

Fig. 1 Comparison between cartesian and Frenet coordinate systems

参考文献[5],能够得到车辆在笛卡尔坐标系下的运动状态和和 Frenet 坐标系运动状态之间的转换公式,这里不再赘述。

### 1.2 参考线及采样

在轨迹规划中,以参考线为基准进行采样是动态规划前的重要步骤。参考线通常代表一种理想的或初步规划的路径,可以是道路中心线、导航路线或其他预定义路径。本文采用 A\* 算法<sup>[13]</sup>规划出一条全局路径作为参考线。而采样的目的是生成一系列离散点,用于离散化路径规划问题,以便动态规划算法能够处理。

### 1.3 动态规划及二次规划

动态规划算法通过将路径规划问题分解为一系列更小的子问题,递归求解这些子问题并存储其结果,从而减

少了重复计算。动态规划可以从包含障碍物的非凸空间中开辟出凸空间,从而利用二次规划的方法对凸优化问题进行求解,得到路径规划的最后路径<sup>[14]</sup>。二次规划问题是一种非线性优化问题,其目标函数为二次型,而约束条件为线性的,即:

$$\begin{aligned} \min & \left( \frac{1}{2} \mathbf{x}^T \mathbf{H} \mathbf{x} + \mathbf{f}^T \mathbf{x} \right) \\ \text{s. t. } & \mathbf{A}_{eq} \mathbf{x} = \mathbf{b}_{eq}, \mathbf{A} \mathbf{x} \leq \mathbf{b} \end{aligned} \quad (1)$$

式中:  $\mathbf{H}$  是二次项的参数矩阵;  $\mathbf{f}$  为一次项的参数矩阵;  $\mathbf{A}_{eq}$  和  $\mathbf{b}_{eq}$  为等式约束的参数矩阵;  $\mathbf{A}$  和  $\mathbf{b}$  为不等式约束的参数矩阵。

## 2 基于虚拟障碍物决策的轨迹规划改进方法

### 2.1 总体框架

本文提出的轨迹规划算法总体框架如图2所示。首先,基于Frenet坐标系进行路径规划,通过自适应聚集采样策略进行采样,之后通过以5次多项式为采样点之间的连接曲线进行路径动态规划,最后通过路径二次规划进一步对所得路径进行优化。其次,通过虚拟障碍物决策模型,完成对静态障碍物和动态障碍物的处理,并根据

动态障碍物的速度进行相应的决策。最后,经过速度规划将生成的路径信息和速度信息进行整合,生成一条完整的轨迹(包含路径、速度、加速度、时间、航向角)。

### 2.2 自适应聚集采样策略

在狭长的空间中,道路的宽度会不断发生变化,如果采用相同间隔的采样点的话,则会产生许多无用的采样点,从而降低了算法效率。另外,无用的采样点也有可能对动态规划的性能造成影响,在一些情况下会出现规划失败的情况。

针对以上问题,本文提出了一种自适应聚集采样策略(adaptive aggregation sampling, AAS),传统采样方式是在Frenet坐标系下以固定的间隔在  $s$  方向和  $l$  方向进行采样。AAS方法则在获取道路边界之后,根据道路的宽度,将这些无用点重新分配到道路中去。此外,AAS方法也能将采样到前方障碍物中的无用点重新分配到其他可行行驶区域中去。如图3所示,设动态规划沿  $s$  方向的采样间隔为  $s_{int}$ ,沿  $l$  方向的采样间隔为  $l_{int}$ ,采样点行数为  $n_r$  ( $n_r$  须为奇数),采样点的列数为  $n_c$ ,则传统的采样方法在Frenet坐标系下的采样点坐标为:

$$(js_{int}, -\frac{1}{2}l_{int}(n_r - 1) + (i - 1)l_{int}) \quad (2)$$

式中:  $j = 1, 2, \dots, n_c; i = 1, 2, \dots, n_r$ 。

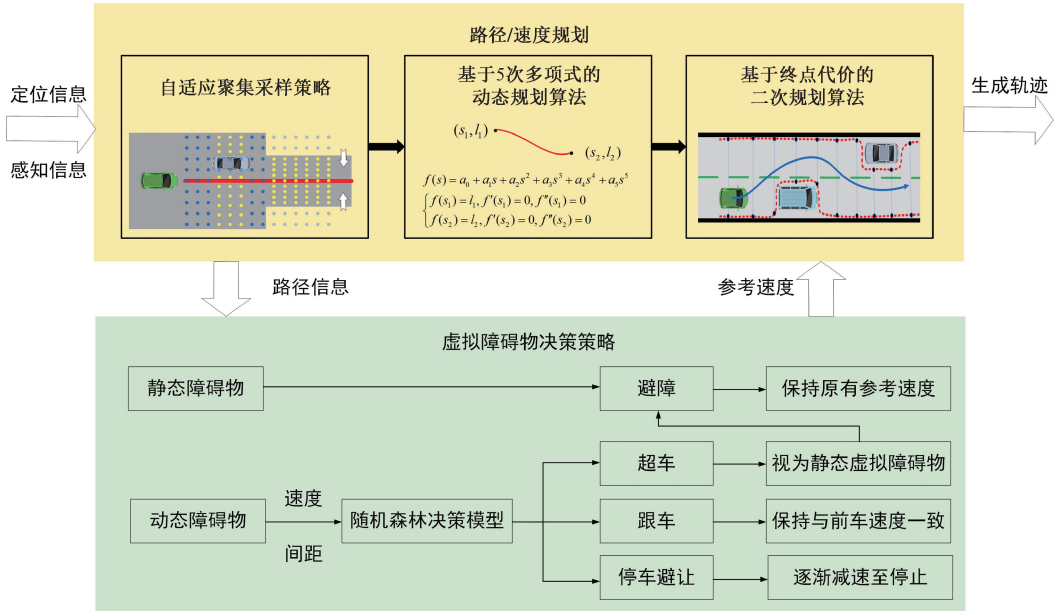


图2 所提轨迹规划方法的结构

Fig. 2 Architecture of the proposed trajectory planning method

设道路宽度为  $d_j$ ,若道路中无障碍物,则自适应聚集采样策略得到的采样点坐标为:

$$(js_{int}, -\frac{1}{2} \frac{d_j}{n_r + 1} (n_r - 1) + (i - 1) \frac{d_j}{n_r + 1}) \quad (3)$$

式中:  $j = 1, 2, \dots, n_c; i = 1, 2, \dots, n_r$ 。若道路中存在障碍物,则可将每个可行行驶区域看作一条新的道路,即可通过式(3)计算采样点坐标。

综上所述,AAS方法能够在采样点总数不变的情况




图 3 自适应聚集采样策略示意图

Fig. 3 Schematic diagram of the adaptive aggregation sampling strategy

下,提高在不同道路下的采样效率。另外,在狭长道路中,采用 AAS 方法能够使采样在  $l$  方向的采样点间隔更小,这更加有利于后续的动态规划及二次规划完成避障,提高避障的成功率以及规划路径的质量。

### 2.3 基于五次多项式的动态规划算法

本文采用基于 5 次多项式的动态规划算法,如图 4 所示,通过构建 5 次多项式作为连接两点之间的曲线。设两端点的坐标分别为  $(s_1, l_1)$  和  $(s_2, l_2)$ ,则连接这两点之间的 5 次多项式为:

$$f(s) = a_0 + a_1s + a_2s^2 + a_3s^3 + a_4s^4 + a_5s^5 \quad (4)$$

为了确定 5 次多项式的系数,需要给定端点的边界条件,即:

$$\begin{cases} f(s_1) = l_1, f'(s_1) = 0, f''(s_1) = 0 \\ f(s_2) = l_2, f'(s_2) = 0, f''(s_2) = 0 \end{cases} \quad (5)$$

这样的边界条件能够保证路径的连续性和平滑性,提高路径的质量。




图 4 基于 5 次多项式的动态规划

Fig. 4 Dynamic trajectory planning based on quintic polynomials

对于路径规划,两点之间的代价由以下函数确定:

$$P = P_{smooth} + P_{ref} + P_{obs} \quad (6)$$

式中:  $P_{smooth}$  表示平滑性代价;  $P_{ref}$  表示参考线代价;  $P_{obs}$  表示障碍物代价。设  $(s_{li}, l_{li})$  表示两端点  $(s_1, l_1)$  和  $(s_2, l_2)$  之间均匀采样的多个点,则平滑性代价为:

$$P_{smooth} = \omega_{11} \sum_i (f'(s_{li}))^2 + \omega_{12} \sum_i (f''(s_{li}))^2 + \omega_{13} \sum_i (f'''(s_{li}))^2 \quad (7)$$

式中:  $P_{smooth}$  表示采样点的各阶导数的加权平方之和;  $\omega_{11}, \omega_{12}, \omega_{13}$  分别表示各阶导数的权重,这项代价保证规划的结果更加平滑。参考线代价为:

$$P_{ref} = \omega_2 \sum_i l_{li}^2 \quad (8)$$

式中:  $P_{ref}$  表示距参考线之间的距离的平方之和;  $\omega_2$  表示参考线代价的权重,这项代价保证规划的结果更接近参考线。障碍物代价为:

$$P_{obs} = \omega_3 \sum_i \sum_j g_{obs}(d_{ij}) \quad (9)$$

式中:

$$d_{ij} = \sqrt{(s_{li} - s_j)^2 + (l_{li} - l_j)^2} \quad (10)$$

$$g_{obs}(d_{ij}) = \begin{cases} 0, & d_{ij} \geq d_{safe} \\ \frac{\omega_{31}}{d_{ij}}, & d_{danger} < d_{ij} < d_{safe} \\ +\infty, & d_{ij} \leq d_{danger} \end{cases} \quad (11)$$

式中:  $d_{ij}$  表示采样点  $(s_{li}, l_{li})$  与坐标为  $(s_j, l_j)$  的障碍物之间的距离;  $d_{danger}$  表示危险距离;  $d_{safe}$  表示安全距离;  $\omega_3$  表示障碍物代价的权重;  $\omega_{31}$  表示单个障碍物的权重系数。这项代价能够保证规划的路径尽可能的远离障碍物。类似的,速度规划中采用以参考速度代价、加速度代价、障碍物代价组成的代价函数。

### 2.4 基于终点代价的二次规划算法

如图 5 所示,蓝色曲线为动态规划得到的路径,通过将障碍物进行隔离,得到能够进行二次规划的凸空间(即红色虚线内)。




图 5 路径二次规划空间

Fig. 5 Path quadratic programming space

本文引入规划终点时的路径状态代价以及动态规划的结果代价,因此,本文采用以下的目标函数:

$$C = C_{smooth} + C_{center} + C_{dp} + C_{end} \quad (12)$$

式中:  $C_{smooth}$  表示平滑性代价;  $C_{center}$  表示凸空间中心代价;  $C_{dp}$  表示动态规划代价;  $C_{end}$  表示终点代价对于平滑性代价。

$$C_{smooth} = \omega_{41} \sum_i l_i^2 + \omega_{42} \sum_i l_i'^2 + \omega_{43} \sum_i l_i''^2 + \omega_{44} \sum_i (l_{i+1}' - l_i')^2 \quad (13)$$

为了简化计算,以前向差分  $(l_{i+1}' - l_i')$  作为三阶导数计算其代价,这项代价保证规划结果更加平滑并且更接近参考线。凸空间中心代价为:

$$C_{center} = \omega_5 \sum_i (l_i - \frac{l_i^{min} + l_i^{max}}{2})^2 \quad (14)$$

这项代价保证规划结果更加接近凸空间中心。动态



规划代价为:

$$C_{dp} = \omega_6 \sum_i (l_i - l_i^{dp})^2 \quad (15)$$

式中:  $l_i^{dp}$  动态规划得到的路径的横向位置。这项代价保证结果更加接近动态规划路径。终点代价为:

$$C_{end} = \omega_7 (l_n^2 + l_n'^2 + l_n''^2) \quad (16)$$

这项代价保证规划终点的状态更加接近原点的状态。

二次规划等式约束主要是对于  $l_i$  的连续性约束。由于  $l_i$  的三阶导数变化较小,因此假设连接  $(s_i, l_i)$  和  $(s_{i+1}, l_{i+1})$  之间的曲线的三阶导数恒为常数  $(l_{i+1}'' - l_i'')/\Delta s$ , 其中  $\Delta s = s_{i+1} - s_i$ , 则这两点处的高阶导数均为0,根据泰勒展开并对两边同时求导,有:

$$\begin{bmatrix} 1 & \Delta s & \frac{1}{3}\Delta s^2 & -1 & 0 & \frac{1}{6}\Delta s^2 \\ 0 & 1 & \frac{1}{2}\Delta s & 0 & -1 & \frac{1}{2}\Delta s \end{bmatrix} \begin{bmatrix} l_i \\ l_i' \\ l_i'' \\ l_{i+1} \\ l_{i+1}' \\ l_{i+1}'' \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \quad (17)$$

以此类推可以得到所有  $l_i$  所对应的约束条件。

不等式约束则是二次规划的范围不能超过动态规划所开辟的凸空间范围。考虑在实际中,车辆是有大小的,因此需要建立车辆模型来对二次规划进行约束。

如图6所示,将无人车辆视为一个长方体模型。其中,点  $P$  为车辆质心,坐标为  $(s_i, l_i)$ ,  $h_1$  和  $h_2$  分别为质心到车头和车尾的距离,  $d$  为车辆宽度,  $\theta$  为车头方向与  $s$  轴之间的夹角,  $Q_1, Q_2, Q_3, Q_4$  为车辆的四个顶点。则能够计算出4个顶点的  $l$  方向的坐标为:

$$\begin{cases} l_{Q_1} = l_i + h_1 \sin \theta + \frac{d}{2} \cos \theta \\ l_{Q_2} = l_i + h_1 \sin \theta - \frac{d}{2} \cos \theta \\ l_{Q_3} = l_i - h_2 \sin \theta - \frac{d}{2} \cos \theta \\ l_{Q_4} = l_i - h_2 \sin \theta + \frac{d}{2} \cos \theta \end{cases} \quad (18)$$

即对于每一个  $l_i$  满足式(19)即可。

$$l_{Q_j}^{min} < l_{Q_j} < l_{Q_j}^{max}, j = 1, 2, 3, 4 \quad (19)$$

## 2.5 虚拟障碍物决策策略

传统的两阶段轨迹规划方法是通过动态规划来完成无人车辆的决策模块(即开辟凸空间)。动态规划是一种轻决策方法,这种决策方法虽然能够处理一些复杂场景,但是在实际场景中不能很好的符合人类的驾驶习惯。在图7所示场景中,自车(绿车)遇到障碍物车辆(蓝车)时候,可以选择超车、跟车或者停车等决策,动态规划模




图6 车辆模型

Fig. 6 Vehicle model

块会根据障碍物车辆与自车的相对位置进行决策,然而在实际中,驾驶人应根据障碍物车辆和自车速度的相对关系执行不同的决策,而传统的阶段轨迹规划方法缺少此环节。因此,本文加入虚拟障碍物决策模块完成对自车决策的优化。




图7 实际道路中的决策

Fig. 7 Decision-making in real-world roads

决策树是一种以树形数据结构来展示决策规则和分类结果的模型,其通过对单个节点路径上的特征进行一系列测试来实现分类,因此被广泛用于建模决策过程<sup>[15]</sup>。将多个决策树结合在一起,则形成了随机森林模型<sup>[16]</sup>。对于分类模型,随机森林会将所有决策树中分类结果数目最多的作为最终结果。本文引入此模型完成对虚拟障碍物的决策。决策树模型分为迭代二叉树三代(iterative dichotomiser 3, ID3)算法<sup>[17]</sup>、C4.5 算法<sup>[18]</sup>、分类回归树(classification and regression tree, CART)算法<sup>[19]</sup>等,这些算法各有特点,考虑到实际情况,本文采用CART算法。CART算法采用基尼指数作为分裂标准,其决策树规模较小、生成决策树的效率较高,适合在实时运行的无人车辆中完成决策。在分类问题中,假设在样本  $T$  有  $n$  种类别,则基尼指数为:

$$G(T) = \sum_{i=1}^n p_i (1 - p_i) = 1 - \sum_{i=1}^n p_i^2 = 1 - \sum_{i=1}^n \left(\frac{N_i}{S}\right)^2 \quad (20)$$

式中:  $p_i$  表示类别  $i$  在样本  $T$  中出现的频率;  $N_i$  表示类别  $i$  在样本  $T$  中的个数;  $S$  表示  $T$  中样本的个数。具体的决策流程即将自车速度、前车速度、两车间距等数据输入到

训练好的随机森林模型中,从而得到相应的决策(超车、跟车或停车),并通过调整参考速度来指导速度规划进行相应的决策。此外,当决策模型判断需要超车时,会将前车视作多个静态虚拟障碍物,从而采用 AAS 方法进行采样,完成超车行为。

3 实验验证

本文实验验证采用 Python 语言,在 Ubuntu 系统 Carla(car learning to act)仿真器中完成仿真测试。Carla 是在虚幻引擎 4(unreal engine 4, UE4)基础开发的一种开源模拟器,能够很好地应用到自动驾驶各个模块的测试和研究中<sup>[20]</sup>。设置 3 组仿真实验和实车测试完成对本文算法的验证。仿真实验平台的 CPU 为 Intel Core i9-10940X,GPU 为 NVIDIA TITAN RTX。实验中所使用的车辆型号均为预设的“tesla model 3”,车辆长度约为 4.8 m,车辆宽度约为 2.1 m。

3.1 静态多障碍物避障实验

分别用快速搜索随机树(rapidly-exploring random trees,RRT)算法、人工势场引导下的 RRT(artificial potential field-RRT, APF-RRT)算法、最大期望规划(expectation maximum planner,EM-planner)算法以及本文方法在不同的静态障碍物场景下进行 100 次实验,测试 4 种算法的性能。

在实际中,避障路径的安全性能是首要考虑的,因此提出距离障碍物最短距离(minimum distance of obstacles, MDO)参数来表示安全性能,该项数据通过计算所有规划路径点(即车辆中心点)中距离最近障碍物中心点距离的最小值得到,若 MDO 值过小,则实际控制中则有出现碰撞的风险,平均 MDO 能够反映算法的安全性能,而 MDO 方差能够反映算法在安全性能上的稳定性,成功率则直观反映了 100 次实验中“成功”规划路径的比例。此外,平均路径长度和平均路径曲率也能直观反映该条路径的质量。因此,分别测试不同算法的路径长度、路径曲率、平均 MDO、MDO 方差以及成功率等指标。

1) 复杂城市场景  
首先测试算法在复杂城市场景下的性能,在 Carla 中使用预设的场景“Town05”,该场景为城市场景,道路较为宽阔,设置复杂的障碍物来测试算法性能。在道路中设置了 4 辆障碍物车。

如图 8(a)所示,由于 RRT 算法的采样存在随机性,因此得到的路径较为曲折,在实际中难以采用;如图 8(b)所示,在人工势场算法的引导下,RRT 算法的采样随机性得到了改善,但是得到的路径质量依然较差;如图 8(c)所示,EM-planner 算法能够得到一条质量较好的路径,然而由于其采样未考虑障碍物车辆,导致其规划的路径出现了贴近障碍物的情况;如图 8(d)所示,本文方法结合了 AAS 方法以及在动态规划、二次规划方面的改进,得到的路径平滑性较高的同时,也兼顾了其安全性。

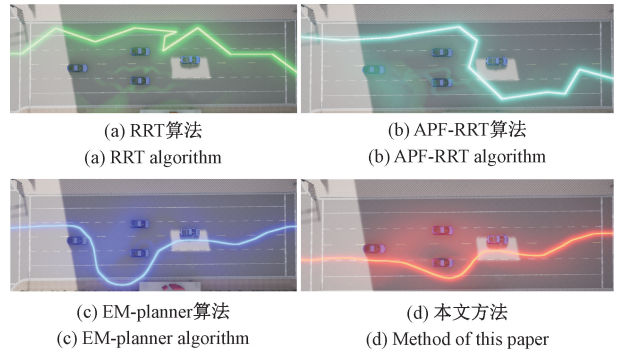


图 8 Carla 复杂城市场景不同算法路径对比图  
Fig. 8 Comparison of paths of different algorithms for complex urban scenes in Carla

由表 1 可得,本文方法相较于 RRT 算法、APF-RRT 算法和 EM-planner 算法,平均路径长度分别减少了约 12.4%、11.4% 和 9.5%;平均路径曲率分别减少了约 95.1%、93.0% 和 71.5%;平均 MDO 分别提高了约 14.6%、3.2% 和 20.6%;MDO 方差分别降低了约 79.7%、51.9% 和 44.9%;成功率分别提高了 44%、36% 和 20%。整体看来,本文方法在路径长度、平滑性、安全性能、规划成功率都相较于传统方法有显著提升。

表 1 复杂城市场景不同算法性能对比  
Table 1 Performance comparison of different algorithms in complex urban scenes

算法	平均路径长度/m	平均路径曲率/m <sup>-1</sup>	平均 MDO/m	MDO 方差/m <sup>2</sup>	成功率/%
RRT	92.35	0.75	1.99	3.69	45
APF-RRT	91.26	0.53	2.21	1.56	53
EM-planner	89.41	0.13	1.89	1.36	69
本文	80.88	0.037	2.28	0.75	89

2) 狭窄乡村场景  
在 Carla 中使用预设的场景“Town07”,该场景为乡

村场景,存在狭窄的道路,适用于测试本文算法的性能。在狭窄的道路上设置 3 辆障碍物车辆。

如图 9(a)、(b) 所示, RRT 算法的随机性仍然使得得到的路径较为曲折, 这会为无人车辆的控制模块带来很大的困难; 如图 9(c) 所示, EM-planner 算法虽然能够成功规划一条平滑性较好的路径, 但在狭窄的道路中, 其采样方法的局限性被放大, 在规划中容易出现贴近障碍物的情况; 如图 9(d) 所示, 本文方法即使在狭长的空间中, 依然能够通过 AAS 方法进行自适应采样, 并通过改进的动态规划以及二次规划, 得到一条质量较高的路径。此外, 在狭窄的空间中, EM-planner 算法的成功率仅为

58%, 且平均 MDO 仅有 1.99 m, 而本文方法则达到了 83% 和 3.69 m, 这表明本文方法更加适用于狭窄区域。

由表 2 可知, 本文方法相较于上述算法, 平均路径长度分别减少了约 14.1%、8.1% 和 2.4%; 平均路径曲率分别减少了约 93.9%、94.1% 和 85.6%; 平均 MDO 分别提高了约 22.6%、23.4% 和 85.4%; MDO 方差分别降低了约 84.8%、78.3% 和 56.6%; 成功率分别提高了 59%、51% 和 25%。

表 2 狭窄乡村场景不同算法性能对比

Table 2 Performance comparison of different algorithms in narrow rural scenes

算法	平均路径长度/m	平均路径曲率/ $m^{-1}$	平均 MDO/m	MDO 方差/ $m^2$	成功率/%
RRT	120.31	0.75	3.01	4.55	24
APF-RRT	112.54	0.79	2.99	2.13	32
EM-planner	105.93	0.32	1.99	1.59	58
本文	103.38	0.046	3.69	0.69	83




图 9 Carla 狭窄乡村场景不同算法路径对比  
Fig. 9 Comparison of paths of different algorithms for narrow rural scene in Carla

3.2 虚拟障碍物决策实验

1) 数据集处理

NGSIM (next generation simulation) 数据集包含了美国公路上的所有车辆在一个时间段内的车辆数据<sup>[21]</sup>。本文使用 NGSIM 城市数据集作为原始数据。

为了将数据分为跟车、超车、停车 3 种类型, 需要对原有数据进行筛选。本文分别参考文献 [22-23] 对车辆跟驰行为和换道超车行为的研究方法对数据集进行处

理, 筛选原则如表 3 所示。

表 3 车辆行为的筛选原则

Table 3 Screening criteria for vehicle behaviors

车辆行为	筛选原则
跟车行为	1. 自车与前车在同一车道
	2. 车辆速度高于 4 km/h
	3. 车头间距在 0~100 m 之间
	4. 跟车时间在 20 s 以上
超车行为	1. 自车车道发生变化
	2. 筛选出换道时刻前 10 s 的车辆数据
停车行为	1. 车辆速度低于 4 km/h
	2. 自车与前车距离小于阈值
	3. 筛选出停车时刻前 10 s 的车辆数据

通过筛选, 得到跟车数据 135 387 个, 超车数据 90 990 个, 停车数据 62 313 个。之后, 对该数据进行处理, 得到自车速度、前车速度、与前车间距等作为随机森林模型的输入。

2) 模型训练及验证

将上述数据以 4 : 1 的比例划分为训练集和测试集, 并通过 5 折交叉验证的方法对模型进行性能评估。

利用 python 中 sklearn 工具箱建立随机森林训练模型。为了寻求决策树中树的最大深度 (max\_depth, 参数 A)、分割内部节点所需最小样本数 (min\_samples\_split, 参数 B)、叶节点上所需的最小样本数 (min\_samples\_leaf, 参数 C) 3 种参数的最优组合值, 本文引入网格搜索算法<sup>[24]</sup>。结果如表 4 所示, 其中随机森林模型采用 10 个决策树结合。

由表 4 可知, 基于网格搜索算法的随机森林模型在对车辆行为决策的预测准确率达到 72.18%, 相较于标准决策树模型预测准确率提高了 11.19%。




表 4 交叉验证集得分对比


模型	A	B	C	得分(预测准确率)/%
决策树	-	-	-	60.99
	36	244	56	71.31(+10.32)
随机森林	-	-	-	67.63(+6.64)
	36	244	56	72.18(+11.19)

3) 测试结果


利用训练的模型,在 Carla 中对其进行测试,结果如图 10 所示。



(a) 超车行为  
(a) Overtaking behavior




(c) 跟车行为  
(c) Car-following behavior




(e) 减速避让行为  
(e) Deceleration avoidance behavior


在图 10(a)中,车辆先加速到参考速度,在感知到前车后虚拟障碍物模块作出超车的决策,车辆则加速进行超车,完毕后再减速到原有速度;在图 10(c)中,车辆在感知到前车后虚拟障碍物模块作出跟车的决策,车辆则减速至前车速度相同后保持;在图 10(e)中,车辆在感知到前车后虚拟障碍物模块作出减速避让的决策,在减速避让前车后,在加速到参考速度继续行驶。结果表明虚拟障碍物决策模块能够正确根据前车与自车关系完成相应的决策。



(b) 超车行为速度变化  
(b) Speed profiles of overtaking behavior



(d) 跟车行为速度变化  
(d) Speed profiles of Car-following behavior



(f) 减速避让行为速度变化  
(f) Speed profiles of deceleration avoidance behavior

图 10 车辆不同行为图及速度变化图

Fig. 10 Vehicle behavior diagrams and speed profiles

3.3 动态多障碍物避障实验

最后测试本文方法在动态多障碍物场景下的性能从

而验证其有效性,由于 RRT 算法和 APF-RRT 算法难以对动态障碍物进行处理,因此分别用 EM-planner 算法以



及本文方法在不同的动态障碍物场景下进行 100 次实验,测试两种算法的性能。

1) 复杂城市场景

在 Carla“Town05”世界地图中设置 3 辆动态车辆,其中两辆车以相同的速度并排行驶,另一辆车以较快的速度行驶,测试不同算法性能。图 11 所示为本文方法在动态避障的全过程。在图 11(a)中,车辆感知到前方两辆车的位置和速度等信息,进行超车的决策;在图 11(b)中,车辆根据规划的轨迹两个动态障碍物之间穿过,完成

超车的决策,并且在超车后感知到第 3 个动态障碍物,重新进行轨迹规划;在图 11(c)中,车辆最终完成与 3 个动态障碍物的交互,继续正常行驶。

由表 5 可得,本文方法相较于 EM-planner 算法,平均路径长度减少了约 2.9%;平均路径曲率减少了约 74.1%;平均 MDO 提高了约 55.3%;MDO 方差降低了约 79.7%;成功率提高了 29%。整体看来,本文方法在路径长度、平滑性、安全性能、规划成功率都相较于传统方法有显著提升。

表 5 复杂城市场景不同算法性能对比

Table 5 Performance comparison of different algorithms in complex urban scenes

算法	平均路径长度/m	平均路径曲率/m <sup>-1</sup>	平均 MDO/m	MDO 方差/m <sup>2</sup>	成功率/%
EM-planner	95.63	0.32	1.23	1.66	57
本文	92.87	0.083	1.91	0.82	86

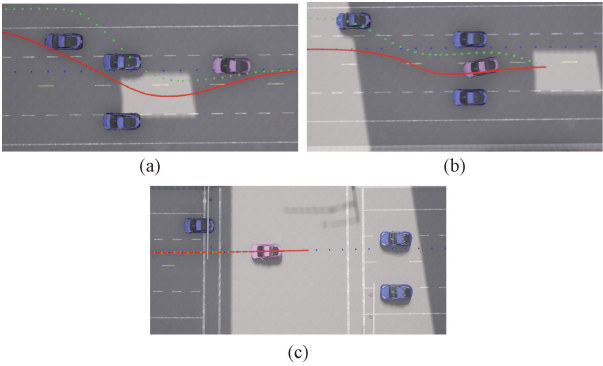


图 11 复杂城市场景动态多障碍物避障 Carla 仿真实验

Fig. 11 Simulation experiment of dynamic multi-obstacle avoidance in complex urban scene in Carla

2) 狭窄乡村场景

在 Carla“Town07”世界地图中设置 3 辆相向的动态车辆,测试不同算法性能。图 12 所示为采用本文方法避障的全过程,无人车辆能够在狭窄的道路中与 3 辆相向而来的障碍物车辆正确进行交互,安全到达终点。

由表 6 可得,本文方法相较于 EM-planner 算法,平均路径长度减少了约 8.3%;平均路径曲率减少了约 76.4%;平均 MDO 提高了约 78.2%;MDO 方差降低了约 45.3%;成功率提高了 36%。在狭窄空间进行动态障碍物避障,AAS 方法能够完成对采样方式进行自适应调整,因此本文方法得到的路径的平滑性和安全性能相较于传统方法大幅度提升;其次虚拟障碍物决策策略能够保证无人车辆做出较为合理的决策,使得本文方法的规划成功率得到大幅度提升。

表 6 狭窄乡村场景不同算法性能对比

Table 6 Performance comparison of different algorithms in narrow rural scenes

算法	平均路径长度/m	平均路径曲率/m <sup>-1</sup>	平均 MDO/m	MDO 方差/m <sup>2</sup>	成功率/%
EM-planner	61.22	0.39	1.19	1.79	43
本文	56.13	0.092	2.12	0.98	79

3.4 实车测试

为测试本文提出的方法的有效性,将其部署到实车进行测试。本文使用的无人车辆配备定位、感知、规划、控制一体化工控机,工控机 CPU 型号为 Intel Core i9-10900,显卡型号为 NVIDIA RTX 3060,感知模块采用 Intel Realsense D455 相机,测试用小车为 HUNTER 阿克曼模型可编程无人地面车辆(unmanned ground vehicle, UGV)。

测试地点选在狭长的走廊,首先测试静态障碍物场景实验,在走廊中随机设置路障作为障碍物以测试本文方法性能,测试结果如图 13 和 14 所示,无人车在感知到

障碍物后,本文方法能够规划出一条无碰撞轨迹,从而完成避障任务。本文方法在该场景下的性能指标如表 7 所示,从中能够得出在静态场景下,本文方法能够快速规划出一条质量较好的轨迹。

表 7 静态障碍物场景下的性能指标

Table 7 Performance metrics in a static obstacle scenario

平均规划耗时/s	最大规划耗时/s	平均跟踪误差/m	最大跟踪误差/m
0.07	0.16	0.06	0.14

接下来测试动态障碍物场景实验,在走廊中设置另一辆匀速行驶的无人小车,如图 15 所示,自车在感知到

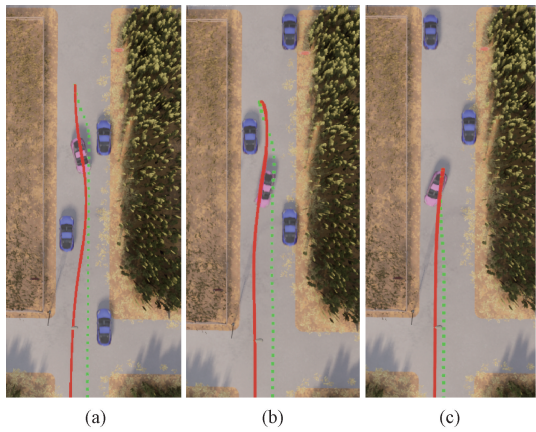


图 12 狭窄乡村场景动态多障碍物避障 Carla 仿真实验  
Fig. 12 Simulation experiment of dynamic multi-obstacle avoidance in narrow rural scene in Carla



图 13 静态障碍物场景实际测试结果  
Fig. 13 Actual test results in static obstacle scenarios

前车后,虚拟障碍物决策模块判断进行跟车,自车则在与前车保持一定距离后,减速至与前车速度相同,保持跟车。本文方法在该场景下的性能指标如表 8 所示,从中能够得出在动态场景下,虚拟障碍物决策模型能够快速作出合理的决策,从而使得无人车辆完成会车任务。

多次测试结果表明,本文提出的方法能够在狭长空间不同场景下完成避障任务,从而证明本文方法的有效性。




图 14 避障局部规划图  
Fig. 14 Local obstacle avoidance planning diagram



图 15 动态障碍物场景实际测试结果  
Fig. 15 Actual test results in dynamic obstacle scenarios

表 8 动态障碍物场景下的性能指标  
Table 8 Performance metrics in a dynamic obstacle scenario

平均规划耗时/s	最大规划耗时/s	平均跟踪误差/m	最大跟踪误差/m
0.12	0.35	0.05	0.15

4 结 论

为了解决传统轨迹规划算法在狭长空间规划成功率低、自适应程度差、不符合人类驾驶习惯等问题,本文提

出了基于虚拟障碍物决策的自适应两阶段轨迹规划方法。首先,本文提出了一种自适应聚集采样策略以及基于5次多项式的动态规划算法和基于终点代价的二次规划算法,从而提高避障的成功率以及规划路径的质量。另外,本文还构建了一种基于随机森林的虚拟障碍物决策模型,使得决策更加合理。通过Carla仿真器进行实验,在静态多障碍物环境和动态多障碍物环境中分别在复杂城市场景和狭窄乡村场景进行测试,本文方法在路径长度、路径平滑性、规划成功率、安全性及其稳定性方面均有所提升。最后,将算法部署到了实际的无人车辆进行测试,小车能够在狭长的环境中完成避障任务,验证了算法的有效性。

## 参考文献

- [1] 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, 58(14): 276-287.
- ZHANG L P, SU T, YAN Y. Trajectory planning method of intelligent vehicle based on sampling area optimization[J]. Journal of Mechanical Engineering, 2022, 58(14): 276-287.
- [2] 余卓平,李奕姗,熊璐. 无人车运动规划算法综述[J]. 同济大学学报(自然科学版), 2017, 45(8): 1150-1159.
- YU ZH P, LI Y SH, XIONG L. A review of the motion planning problem of autonomous vehicle[J]. Journal of Tongji University (Natural Science), 2017, 45(8): 1150-1159.
- [3] 伞红军,杨晓园,陈久朋,等. 基于拟水流算法在移动机器人路径规划中的应用[J]. 仪器仪表学报, 2024, 45(7): 263-278.
- SAN H J, YANG X Y, CHEN J P, et al. Research on path planning of mobile robot based on the stream algorithm[J]. Chinese Journal of Scientific Instrument, 2024, 45(7): 263-278.
- [4] 张俊坤,陈勇,郭晓光. 面向车辆换道工况的智能车轨迹规划研究[J]. 机械设计与制造, 2024(3): 194-198, 204.
- ZHANG J K, CHEN Y, GUO X G. Research on intelligent vehicle trajectory planning for lane changing cases[J]. Machinery Design & Manufacture, 2024(3): 194-198, 204.
- [5] 赵俊武,曲婷,胡云峰. 基于自适应采样的智能车辆轨迹规划方法[J]. 吉林大学学报(工学版), 2025, 55(8): 2802-2816.
- ZHAO J W, QU T, HU Y F. Trajectory planning for intelligent vehicles based on adaptive sampling[J]. Journal of Jilin University (Engineering and Technology Edition), 2025, 55(8): 2802-2816.
- [6] 王勤,魏利胜. 基于改进HLO和动态窗口的AGV动态避障路径规划算法[J]. 电子测量与仪器学报, 2025, 39(2): 213-221.
- WANG Q, WEI L SH. Dynamic obstacle avoidance path planning algorithm for AGVs based on improved HLO and dynamic windows [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(2): 213-221.
- [7] QIE T, WANG W, YANG C, et al. An improved model predictive control-based trajectory planning method for automated driving vehicles under uncertainty environments [J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 24(4): 3999-4015.
- [8] HU J, ZHANG Y, RAKHEJA S. Adaptive lane change trajectory planning scheme for autonomous vehicles under various road frictions and vehicle speeds [J]. IEEE Transactions on Intelligent Vehicles, 2022, 8(2): 1252-1265.
- [9] CHENG S, PENG H N, DONG X X, et al. Chassis global dynamics-oriented trajectory planning for automated vehicles[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2024, 54(2): 950-959.
- [10] MARTINSEN A B, LEKKAS A M, GROS S. Optimal model-based trajectory planning with static polygonal constraints[J]. IEEE Transactions on Control Systems Technology, 2021, 30(3): 1159-1170.
- [11] 梅芳超. 基于Frenet坐标系的无人车局部轨迹规划与跟踪控制算法研究[D]. 广州:华南理工大学, 2023.
- MEI F CH. Research on local trajectory planning and tracking control algorithm of unmanned vehicle based on frenet coordinate system [D]. Guangzhou: South China University of Technology, 2023.
- [12] 殷键,陈国权. 基于LQR的船舶自主靠泊策略研究[J]. 仪器仪表学报, 2024, 45(9): 227-236.
- YIN J, CHEN G Q. Autonomous berthing strategy based on LQR [J]. Chinese Journal of Scientific Instrument, 2024, 45(9): 227-236.
- [13] LIN Y, FENG C, WANG Z, et al. UAV design and control with A\* algorithm[J]. International Core Journal of Engineering, 2021, 7(12): 221-226.
- [14] 肖应学,何超,包广元. 基于二次规划的智能网联汽车路径规划算法[J]. 机电工程技术, 2024, 53(4): 41-44.
- XIAO Y X, HE CH, BAO G Y. Path planning algorithm for intelligent networked vehicles based on quadratic programming [J]. Mechanical & Electrical Engineering



- Technology, 2024, 53(4): 41-44.
- [15] LUO T, WANG J, FU T, et al. Risk prediction for cut-ins using multi-driver simulation data and machine learning algorithms: A comparison among decision tree, GBDT and LSTM [J]. International journal of transportation science and technology, 2023, 12(3): 862-877.
- [16] 张学连. 基于多源参数的驾驶行为模式识别方法研究[D]. 重庆: 重庆交通大学, 2021.  
ZHANG X L. Research on driving behavior pattern recognition method based on multi-source parameters[D]. Chongqing: Chongqing Jiaotong University, 2021.
- [17] 秦易晋. 智能网联车驾驶行为决策和 MPC 控制器设计[D]. 武汉: 武汉理工大学, 2020.  
QIN Y J. Design of driving behavior decision and MPC controller for intelligent connected vehicle[D]. Wuhan: Wuhan University of Technology, 2020.
- [18] 郭丹丹, 王宽田. 双足机器人步态控制的 C4.5 决策树算法研究[J]. 计算机仿真, 2024, 41(10): 434-437, 452.  
GUO D D, WANG K T. C4.5 decision tree algorithm for gait control of biped robot[J]. Computer Simulation, 2024, 41(10): 434-437, 452.
- [19] ZHANG C, CHAI S, CUI L, et al. Road condition recognition in self-driving cars based on classification and regression tree [J]. ICIC Express Letters, Part B: Applications, 2019, 10(12): 1115-1122.
- [20] 姚悦, 吉明佳, 杨霄. 基于改进 PPO 算法的自动驾驶技术研究[J]. 电子测量技术, 2023, 46(8): 162-168.  
YAO Y, JI M J, YANG X. Research on autonomous driving technology based on improved PPO algorithm[J]. Electronic Measurement Technology, 2023, 46(8): 162-168.
- [21] PRABHAKARAN N, SUDHAKAR S M. Retraction Note: Fuzzy curvilinear path optimization using fuzzy regression analysis for mid vehicle collision detection and avoidance system analyzed on NGSIM I-80 dataset (real-road scenarios)[J]. Neural Computing and Applications, 2024, 36(22): 14013-14013.
- [22] 高云峰, 赵雪, 沈阳, 等. 基于 NGSIM 数据的高速公路客货混合车流改进跟驰模型[J]. 公路交通科技, 2023, 40(9): 187-196.  
GAO Y F, ZHAO X, SHEN Y. An improved car-following model for mixed passenger and freight traffic on expressway based on NGSIM data [J]. Journal of Highway and Transportation Research and Development, 2023, 40(9): 187-196.
- [23] 陈亮, 冯延超, 李巧茹. 基于 Multi-class SVM 的车辆换道行为识别模型研究[J]. 安全与环境学报, 2020, 20(1): 193-199.  
CHEN L, FENG Y CH, LI Q R. Probe into the Multi-class SVM-based recognition model for the vehicle lane-altering behaviors [J]. Journal of Safety and Environment, 2020, 20(1): 193-199.
- [24] RIMAL Y, SHARMA N, ALSADOON A. The accuracy of machine learning models relies on hyperparameter tuning: student result classification using random forest, randomized search, grid search, Bayesian, genetic, and Optuna algorithms [J]. Multimedia Tools and Applications, 2024, 83(30): 74349-74364.

## 作者简介



张俊豪, 2023 年于东南大学获得学士学位, 现为东南大学硕士研究生, 主要研究方向为无人车辆智能轨迹规划技术。

E-mail: yyjszjh@qq.com

**Zhang Junhao** received his B. Sc. degree from Southeast University in 2023. Now he is a M. Sc. candidate in Southeast University. His main research interest includes intelligent trajectory planning technology for unmanned vehicles.



潘树国 (通信作者), 2007 年于东南大学获得博士学位, 现为东南大学教授, 主要研究方向为高精度定位与智能导航技术。

E-mail: psg@seu.edu.cn

**Pan Shuguo** (Corresponding author) received his Ph. D. degree from Southeast University in 2007. Now he is a professor in Southeast University. His main research interest includes high-precision positioning and intelligent navigation technology.