·复杂场景中智能驾驶路径规划技术专题·

复杂泊车场景下平行泊车路径规划研究*

谢韵清　郑燕萍　鞠飞

（南京林业大学汽车与交通工程学院，南京 210037）

【摘要】针对复杂泊车场景中自动泊车规划时间长、路径质量欠佳等问题，提出了一种基于智能概率地图的双向快速随机搜索树（SPM-Bi-RRT*）平行泊车路径规划算法。定义了3种复杂泊车场景，即狭窄车位、通道受限及存在障碍物场景，并基于向量叉乘法建立了简化车辆的碰撞检测模型。在采样策略方面，通过逐级限制采样区域，引入斥力偏置和先验路径，构建了基于概率地图的智能采样机制，从而提升了算法在搜索空间中的采样效率。同时，改进RS曲线的扩展代价并采用自适应动态步长策略，进一步结合剪枝操作与B样条曲线对冗余路径进行优化处理，有效提高了路径规划的成功率和搜索效率。仿真结果表明，提出的SPM-Bi-RRT*算法在3种复杂泊车场景中均能规划出平滑且无碰撞的路径，相较于原始RRT*算法，搜索时间分别减少56.67%、49.63%、58.42%，路径长度分别缩短7.74%、3.84%、3.65%。

主题词：平行泊车　路径规划　改进RRT*算法　概率地图　Reeds-Shepp曲线

中图分类号：U461　　**文献标志码：**A　　**DOI:** 10.19620/j.cnki.1000-3703.20250756

Research on Parallel Parking Path Planning in Complex Parking Scenarios

Xie Yunqing, Zheng Yanping, Ju Fei

（Nanjing Forestry University, College of Automobile and Traffic Engineering, Nanjing 210037）

【Abstract】To address issues such as long planning time and low success rate in automated parking under complex scenarios, this paper proposes a parallel parking path planning algorithm based on a Smart Probability Map-enhanced Bidirectional Rapidly-exploring Random Tree* (SPM-Bi-RRT*). 3 types of complex parking scenarios are defined: narrow parking spaces, constrained passageways, and obstacle-present environments. A simplified vehicle collision detection model is established using the vector cross product method. The sampling strategy is innovatively improved by hierarchically partitioning the sampling space to reduce computational complexity. A probability map is constructed based on repulsive bias and prior paths to guide algorithmic sampling. Path extension is performed using improved Reeds-Shepp curves with adaptive dynamic step sizes. Finally, path smoothing and optimization are achieved through pruning and cubic B-spline curves. Simulation results show that the proposed SPM-Bi-RRT* algorithm can generate smooth, collision-free paths in all three complex parking scenarios. Compared with the original RRT* algorithm, the search time is reduced by 56.67%, 49.63%, and 58.42%, respectively, and the path length is shortened by 7.74%, 3.84%, and 3.65%.

Key words: Parallel parking, Path planning, Improved RRT* algorithm, Probability map, Reeds-Shepp curve

【引用格式】谢韵清，郑燕萍，鞠飞．复杂泊车场景下平行泊车路径规划研究[J]. 汽车技术，2026(6): 21-29.

XIE YUN Q, ZHENG Y P, JU F. Research on Parallel Parking Path Planning in Complex Parking Scenarios[J]. Automobile Technology, 2026(6): 21-29.

1　前言

机动车保有量激增及停车占地资源稀缺导致泊车场景复杂、泊车难度增加，而随着汽车智能化水平的提高，自动泊车成为解决该问题的有效手段之一。目前自动泊车路径规划方法包括曲线插值法、数值优化法、图搜索算法、随机采样算法等。

曲线插值方法主要包括曲线组合[1]和插值拟合[2]，

*基金项目：国家自然科学基金项目（52402476）。

通信作者：郑燕萍（1965—），教授，主要研究方向为电动汽车、智能汽车的路径跟踪、汽车现代设计理论与方法，zhengyp@njfu.com.cn。

其优势在于计算效率高，但面对复杂泊车场景应用时存在局限。数值优化法将泊车运动规划转化为约束条件下的最优控制问题[3-5]，具有较强的求解能力，但复杂场景下计算量过大、实时性较差。

图搜索算法按照广度或深度优先在栅格地图中搜索最优路径。Yang等[6]引入动态窗口改进A*算法，有效去除了泊车规划中产生的冗杂点。Lian[7]使用A*搜索算法获得全局粗略泊车轨迹走廊，并依此猜测最优控制问题的初始解。任秉韬等[8]提出可变半径Reeds-Shepp曲线的混合A*算法并优化复杂泊车路径。秦东晨等[9]针对受限泊车通道，将泊车过程分段并改进混合A*算法的碰撞风险函数。但图搜索算法的规划能力和实时性受地图分辨率的限制，且改进优化时需要考虑效率问题，尤其是复杂场景下的时间成本控制。

随机采样算法通过在整个搜索空间均匀随机采样获取增量式节点序列实现路径规划，其中快速扩展随机树（Rapidly-exploring Random Tree, RRT）应用广泛。Shin等[10]针对狭窄杂乱的泊车环境，提出了基于期望方向的RRT算法。Jhang等[11]采用Reeds-Shepp曲线作为扩展方式，并构建了一个符合人类驾驶行为的代价评估函数。Ding[12]提出了EP-RRT*算法，利用贪婪启发式搜索策略在采样区域内迭代搜索。姚智龙等[13]建立避障采样函数和径向采样函数提高Bi-RRT*算法的搜索效率。但复杂泊车场景会限制RRT*算法的扩展能力和搜索效率，且需要考虑路径平滑的问题。

针对现有路径规划算法在复杂泊车场景中存在的规划时间长、路径质量欠佳等问题，本文提出了一种基于智能概率地图（Smart Probability Map-enhanced，SPM）的双向快速随机搜索树SPM-Bi-RRT*路径规划算法，引入SPM改进Bi-RRT*算法的采样策略，利用改进代价Reeds-Shepp曲线和自适应动态步长进行路径扩展，通过剪枝和B样条曲线进行路径平滑优化。本文以平行泊车为例阐述该方法的具体应用。

2 车辆模型与泊车场景分析

2.1 车辆运动学模型

车辆在泊车过程中，速度相对较低，可以认为车轮只进行纯滚动和转向运动，忽略车辆侧倾和轮胎滑移的情况。基于阿克曼转向原理，将车辆简化为两轮模型，车辆外轮廓简化为矩形刚体，建立以车辆后轴中心为参考点的运动学模型，如图1所示。

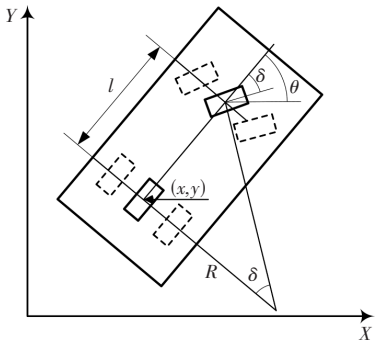


图1 车辆运动学示意

建立的车辆运动学方程为：

$$\begin{bmatrix}\dot{x}\\ \dot{y}\\ \dot{\theta}\end{bmatrix}=\begin{bmatrix}v\cos\theta\\ v\sin\theta\\ v\tan\delta/l\end{bmatrix} \tag{1}$$

式中：(x,y)为车辆后轴中心点坐标，θ为航向角，v为车辆后轴中心点车速，l为车辆轴距，δ为等效前轮转角。

根据图1所示几何关系，车辆后轴中心处的转弯半径和等效前轮转角间关系式为：

$$R = l/\tan\delta \tag{2}$$

式中：R为车辆后轴中心处的转弯半径。

本文研究车辆的基本参数如表1所示。

表1 车辆基本参数

参数	数值
车长L/mm	3 950
车宽W/mm	1 970
轴距l/mm	2 480
前悬l_f/mm	800
后悬l_r/mm	670
最大等效前轮转角δ_{max}/rad	0.524

2.2 复杂泊车场景分析

根据GB/T 41630—2022《智能泊车辅助系统性能要求及试验方法》，设定标准平行泊车的车位：长为6 m，宽为2.5 m，泊车通道宽为5.5 m，如图2黑色框线所示。相比标准的停车位，实际泊车场景往往面临更加复杂的情况，通过对复杂泊车工况的整理和分析，本文定义以下3种典型的复杂泊车场景，如图2所示：

a. 狭窄车位。狭窄车位指目标车位尺寸小于标准停车位尺寸，如图2橙红色区域所示，当车位长度L_p逐步接近车辆外形尺寸时，车辆无法直接以最小转弯半径单步泊入车位，必须在车位内进行多步调整。

b. 通道受限。通道受限指目标车位附近的泊车通道出现空间受限的情况，如图2蓝色区域所示，表现为泊车通道宽度W_r变窄，或车辆行驶方向通道被占用，泊车过程会借用部分车位空间进行位姿调整。

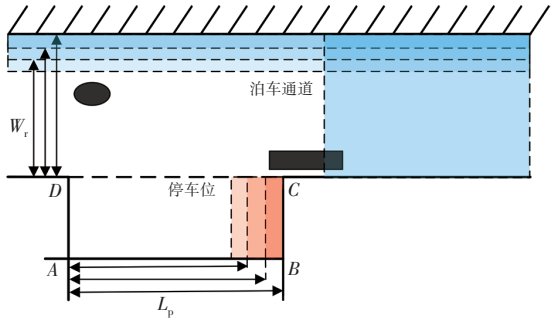


图2　复杂泊车场景示意

c. 障碍物情况。障碍物情况指车位内或者泊车通道中存在障碍物，如图2黑色形状所示，对于不同形状的障碍物，可将其简化为包络轮廓的矩形和圆形，车辆在泊入车位过程中，必须绕行以避开障碍物。

根据3种复杂泊车场景的定义，本文在标准平行泊车尺寸的基础上，对泊车空间进行相应缩减，以构造复杂泊车环境。

2.3　泊车碰撞检测模型

车辆在泊车过程中，必须保证行驶路径的安全性，不能与车位边界线或障碍物发生碰撞。目前常见的碰撞检测方法包括栅格占用法和包围盒法，其精度和效率受栅格分辨率或包围盒形状的限制，难以兼顾。

为了实现车辆在各个复杂泊车场景下快速规划安全无碰撞的泊车路径，本文通过向量叉乘法建立碰撞检测模型。用多边形表示障碍物轮廓，用折线段表示车位边界线，逐一选取车辆轮廓线段 MN 和车位边界线、障碍物轮廓线段 PQ，通过式(3)和式(4)进行相交判断：

$$\begin{cases} \max(M_x,N_x) < \min(P_x,Q_x) \\ \max(M_y,N_y) < \min(P_y,Q_y) \\ \max(M_x,N_x) > \min(P_x,Q_x) \\ \max(M_y,N_y) > \min(P_y,Q_y) \end{cases} \tag{3}$$

$$\begin{cases} (\boldsymbol{MN} \times \boldsymbol{MP}) \cdot (\boldsymbol{MN} \times \boldsymbol{MQ}) < 0 \\ (\boldsymbol{PQ} \times \boldsymbol{PM}) \cdot (\boldsymbol{PQ} \times \boldsymbol{PN}) < 0 \end{cases} \tag{4}$$

式中：M_x、N_x、P_x、Q_x 为各线段端点的横坐标，M_y、N_y、P_y、Q_y 为各线段端点的纵坐标。

对于所选取的线段 MN 和线段 PQ，首先判断是否满足式(3)中任意一个条件，若满足，则2条线段不相交；若都不满足，再判断是否同时满足式(4)中条件，若同时满足，则2条线段相交。

通过这种方法检测车辆是否与车位及障碍物轮廓线相交，进而判断是否发生碰撞。该方法能准确描述车辆与障碍物的关系，满足复杂泊车场景的精度且计算效率高。

3　改进RRT*路径规划算法

RRT*算法在复杂泊车场景应用中，规划出的泊车路径会有较多折角，平滑性不足，难以直接满足车辆运动学约束；算法在采样过程中完全随机，复杂泊车场景会进一步增加搜索空间的复杂度，导致其搜索效率和收敛速度降低，甚至规划失败。

针对上述问题，本文提出一种SPM-Bi-RRT*路径规划算法。通过SPM改进RRT*算法中的采样策略、自适应动态调整步长并改进路径扩展方式，提升在复杂泊车场景中的搜索效率，同时引入剪枝和平滑处理机制改善路径的平滑性。SPM-Bi-RRT*的算法流程如图3所示。

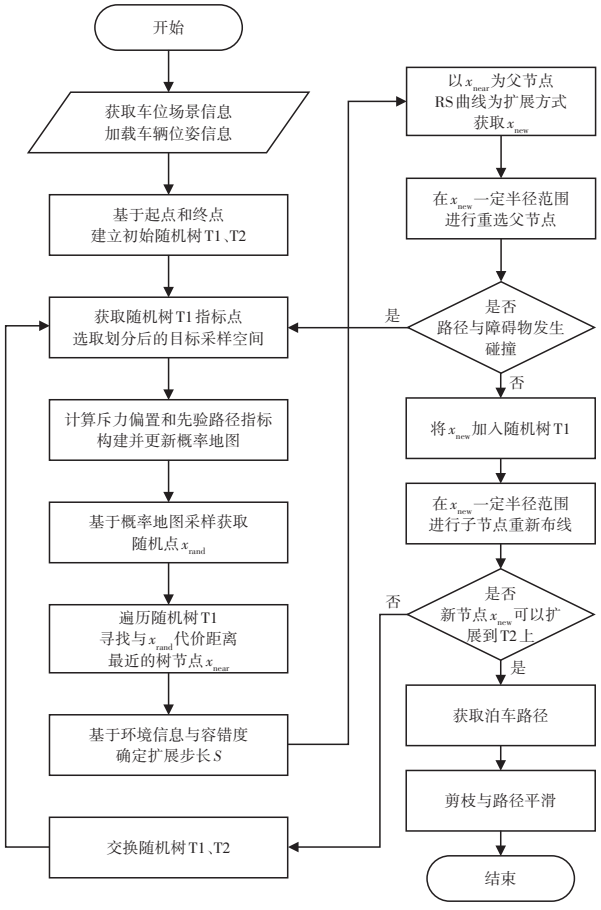


图3　算法流程

3.1　基于概率地图的采样策略

纯随机的采样策略面对复杂泊车场景时，会因障碍物或空间限制无法获取有效节点，导致算法陷入局部困境。为此，本文通过限制采样区域和构建概率地图引导采样过程，提升算法在复杂泊车场景中的适应性和效率。

3.1.1　区域划分

概率地图的精度和计算效率受栅格分辨率的限制，若对整个采样空间进行栅格化处理，会导致概率地图的

计算量剧增。本文通过逐级划分采样区域，将整个采样空间逐级划分为多个区域，并在最小的子空间内进行栅格化处理，同时兼顾概率地图的精度与计算效率。

泊车过程中，由于车辆在泊车通道和车位内的行驶状态存在差异，首先对车道区域和车位区域分别进行采样空间的划分。车道采样空间和车位采样空间的划分如图4和图5所示。

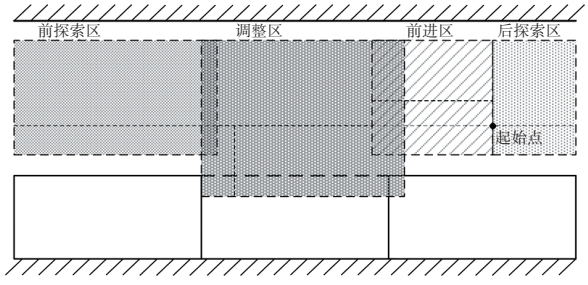


图4　车道采样空间

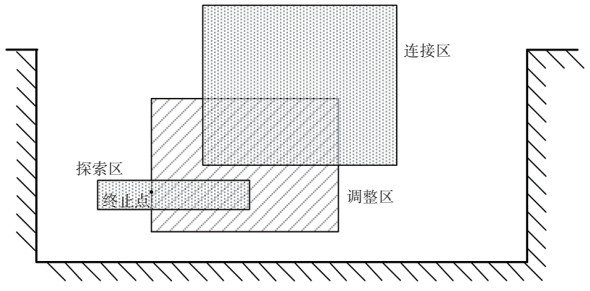


图5　车位采样空间

车道采样空间共分为4个主要区域，包括后探索区、前进区、调整区及前探索区。各采样空间在划分时，将道路的边界向内缩短1/2后悬长度l_r的距离，进一步限制采样空间。各主要区域进一步划分为更小的区域，子区域的划分依据车辆实际的运动情况和算法预搜索情况，具体划分情况如图4所示。

车位采样空间共分为3个主要区域，包括探索区、调整区以及连接区。由于车辆外廓尺寸的限制，车位内可行区域也相应较小，车位采样空间的实际尺寸相比车道采样空间更加狭窄，无需进行下一级的子空间划分，具体划分情况如图5所示。

以上完成了对搜索空间的划分，而目标采样空间的选择依据随机树的生长状况，需要选取随机树指标点进行表征，本文选取的指标点如下：

$$\begin{cases}(x_{\text{new}},y_{\text{new}})=(x_{\max n},y_{\max n})\\(x_{\text{close}},y_{\text{close}})=\arg\min\limits_{i\in\{1,2,\cdots,m\}}\{\sqrt{(x_{\text{goat}}-x_i)^2+(y_{\text{goat}}-y_i)^2}\\(x_n,y_n)=\left(\frac{1}{n}\sum_{i=1}^{n}x_i,\frac{1}{n}\sum_{i=1}^{n}y_i\right)\\(x_N,y_N)=\left(\frac{1}{N}\sum_{i=1}^{N}x_i,\frac{1}{N}\sum_{i=1}^{N}y_i\right)\end{cases}\tag{5}$$

式中：$(x_{\text{new}},y_{\text{new}})$为最后一个加入随机树的节点，$\max n$为最大的随机树节点索引，$(x_{\text{close}},y_{\text{cloes}})$为最接近目标点的节点，$(x_{\text{goat}},y_{\text{goat}})$为目标点，$(x_n,y_n)$为后$n$个随机树节点的平均值，$(x_N,y_N)$为全体随机树节点的平均值。

3.1.2　概率地图

选定目标采样区域后，再将其进行栅格处理，综合随机树以及障碍物等信息，建立栅格概率启发函数，从而构建概率地图指导随机树采样。本文结合随机采样、斥力偏置以及先验路径的思想构建概率地图的启发函数。

人工势场法通过将环境等效为虚拟物理势能场，引导目标从高势能点沿梯度方向向低势能点移动。其中，斥力场由泊车场景中车位边界线和障碍物的合力场组成，斥力场函数$U_{\text{rep}}(q)$为：

$$U_{\text{rep}}(q)=\begin{cases}0 & d(q,q_{\text{obs}})>d_0\\\dfrac{1}{2}K_{\text{rep}}\left(\dfrac{1}{d(q,q_{\text{obs}})-d_0}\right)^2 & d(q,q_{\text{obs}})\leqslant d_0\end{cases}\tag{6}$$

式中：K_{rep}为斥力系数，d_0为斥力影响半径，$d(q,q_{\text{obs}})$为当前位置q与障碍物q_{obs}间的距离。

当表征随机树的指标点位于斥力场中，其梯度方向即为当前节点期望的搜索方向，各栅格斥力偏置作用函数$\theta_i(x_i,y_i)$为：

$$\theta_i(x_i,y_i)=\arccos\left(\frac{\nabla U_{\text{rep}}(q_{\text{index}})\cdot v_i}{\|\nabla U_{\text{rep}}(q_{\text{index}})\|\|v_i\|}\right)\tag{7}$$

式中：$\nabla U_{\text{rep}}(q_{\text{index}})$为指标点的梯度方向，$v_i$为搜索空间中的指标点到栅格点的方向。

车辆在复杂泊车场景内无法进行大幅度转向调整，因此只选取$|\theta|$小于$\pi/2$的角度，并通过高斯分布函数转化为采样概率，表达式为：

$$P_{1i}(\theta_i)=\mathrm{e}^{-\frac{2\theta_i^2}{2\sigma^2}}\tag{8}$$

式中：$P_{1i}(\theta_i)$为栅格斥力偏置采样概率，σ为偏置角标准差。

栅格点与梯度方向的偏置夹角越小，则其采样概率越高，由此构建基于斥力偏置的概率地图。通过概率地图即可实现高效采样点的选择，扩展方向为选定采样点在斥力场中的梯度方向。

仅基于斥力偏置的概率地图作为采样环节，采样节点容易遇到局部最优和振荡，导致泊车路径出现冗余路段，因此，在采样环节中引入基于先验路径概率地图作为全局优化项缓解上述问题。

针对定义的复杂泊车场景，进行大量泊车先验规划，通过贪心路径长度淘汰低质量路径，积累可行且较

优的先验路径数据，并将数据点映射至离散化的搜索空间中，即统计路径数据中落在目标采样区中各栅格内的节点数量，进行概率分布映射，表达式为：

$$P_{2i}(\mathrm{num}_i)=\frac{\mathrm{num}_i(x_i,y_i)}{\sum_{i=n}^{n}\mathrm{num}_i(x_i,y_i)} \tag{9}$$

式中：$P_{2i}(\mathrm{num}_i)$为栅格先验路径采样概率，$\mathrm{num}_i(x_i,y_i)$为栅格区域的路径点数量，n为栅格数量。

对于采样点的扩展方向，路径点中同样存在航向角信息，但车辆面临的复杂泊车场景不同，且不同路径还会经过同一栅格，因此采用类别存储和选取，具体如下：

a. 若路径点的航向角偏差不超出10°时，将其定为一种角度类型，存储并更新为平均值。

b. 若路径点的航向角偏差超出10°，其为新的角度类型。

c. 考虑到计算效率和实际情况，一般仅存储4个类型的航向角且优先保留偏差距离大的角度。

d. 采样点角度从上述存储角度类型中随机选取。

分别构建斥力偏置和先验路径2种概率地图，通过采样策略进行地图选取，同时为确保RRT*算法本身的随机性和概率完备性，保留随机采样环节，采样策略基于轮盘赌选取采样方式：

$$\begin{cases}\mathrm{Random} & p\leqslant 0.1\\ \mathrm{Repulsive} & 0.1<p\leqslant 0.55\\ \mathrm{Prior} & p>0.55\end{cases} \tag{10}$$

式中：p为[0,1]之间的随机数，Random为随机采样环节，Repulsive为斥力偏置概率地图采样，Prior为先验路径概率地图采样。

3.2 自适应动态步长策略

原始RRT*算法随机树的扩展步长通常为固定值，对于复杂泊车场景，其影响算法规划成功率和搜索效率。因此，本文对算法引入自适应动态步长策略，如图6所示。

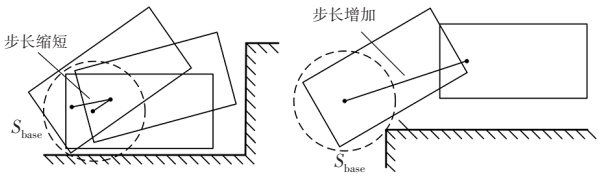


图6 自适应动态步长策略示意

对于泊车空间相对受限的区域，为了保证车辆能在该区域进行精准的位姿调整，需要减小步长，确保车辆顺利入库；而对于相对开阔的区域，可以适度增大步长，使车辆快速驶向目标节点，缩短算法搜索时间，提高规划速度。

步长自适应动态调整受以下3个因素影响：

a. 当前节点附近的邻近节点数量。邻近节点数量反映了所在区域的节点拥挤程度，统计当前节点领域半径r范围内的树节点数量，邻近点影响因子q_1的计算公式为：

$$q_1(N_{\mathrm{node}})=\frac{1}{\alpha\ln(N_{\mathrm{node}}+1)} \tag{11}$$

式中：N_{node}为当前节点的邻近点数量，α为邻近点灵敏度系数。

b. 当前节点附近的障碍物密度。障碍物的密集程度直接影响步长大小，计算当前节点领域半径r范围内的障碍物密度，障碍物影响因子q_2的计算公式为：

$$q_2(\rho_{\mathrm{obs}})=\sqrt{\mathrm{e}^{-\beta\rho_{\mathrm{obs}}}} \tag{12}$$

式中：ρ_{obs}为当前节点的障碍物密度，β为障碍物密度系数。

c. 当前节点容错度。随机树生长过程中，若某一节点的扩展未能通过碰撞检测，其父节点容错度相应增加，容错度越大说明节点所在区域扩展难度越大，容错度影响因子q_3的计算公式为：

$$q_3(\rho_{\mathrm{error}})=\begin{cases}1 & \rho_{\mathrm{error}}<10\\ \mathrm{e}^{-\gamma*(\rho_{\mathrm{error}}-a)} & 10\leqslant\rho_{\mathrm{error}}\leqslant 35\\ \mathrm{e}^{-\gamma*(b-a)} & \rho_{\mathrm{error}}>35\end{cases} \tag{13}$$

式中：ρ_{error}为当前节点的容错度，γ为容错度系数。

关于节点容错度，复杂环境中扩展出的新节点由于动态步长的限制基本上与父节点处于同一区域，因此会直接继承父节点的容错度，只有当节点连续3次直接扩展出无碰路径时，说明当前扩展已经脱离复杂区域，此时新节点的容错度将直接减半。

综合以上影响因素，考虑到实际泊车情况，引入步长上下限约束，实际步长*Step*公式为：

$$\begin{cases}S=\omega_0\cdot S_{\mathrm{base}}\cdot q_1(N_{\mathrm{node}})\cdot q_2(\rho_{\mathrm{obs}})\cdot q_3(\rho_{\mathrm{error}})\\ S=\min(\max(S,S_{\min}),S_{\max})\end{cases} \tag{14}$$

式中：S_{base}为基础步长，$S_{\min}$为最小步长，$S_{\max}$为最大步长，ω_0为步长控制系数。

3.3 改进代价的Reeds-Shepp曲线

原始RRT*算法在扩展过程中利用直线连接新节点，难以满足车辆的运动学约束，因此，本文采用Reeds-Shepp曲线代替直线进行节点之间的扩展连接。

Reeds-Shepp是由多段圆弧和直线组合而成的曲线，包括9类48种曲线类型，通过选择代价最小的曲线组合，获得车辆从当前位姿到目标位姿的最短行驶路径。实际复杂泊车场景中，RS曲线选择的连接组合相

对单一，尤其是车辆在受限空间进行位姿调整时，难以实现90°的转向。为了减少车辆位姿过度调整，提升路径规划效率，仅启用以下6类RS曲线组合类型：$\{C|C|C,\ CC|C,\ C|CC,\ CSC,\ CC_\beta|C_\beta C,\ CC_\beta C_\beta|C\}$。

RRT*算法通过最小化节点间的路径代价值进行节点的重新布线和父节点重选，当车辆处于复杂泊车场景时，如果单纯以RS曲线的长度作为节点间的代价值，泊车路径会产生较多的转向和反向行驶，影响舒适性和跟踪控制难度。为了减少车辆在泊车过程中出现的倒车、转向、换挡次数，对RS曲线路径代价进行调整，增加相应惩罚系数：

$$C_{RS} = p_{1\times4}\cdot[L_{\text{forw}},L_{\text{back}},N_{\text{reve}}\cdot L_{\text{reve}},N_{\text{curv}}\cdot L_{\text{curv}}]^{\mathrm{T}} \quad (15)$$

式中，L_{forw}为前进路径长度；L_{back}为倒车路径长度；L_{reve}为换向路径长度；L_{curv}为转向路径长度；N_{reve}为换向次数；N_{curv}为转向次数；$p_{1\times4}$为惩罚系数，可以根据驾驶偏好和实际工况设置。

3.4 剪枝和路径平滑

经过以上对RRT*算法的改进，生成的泊车路径依旧会存在冗余，需要进行整体路径优化和剪枝操作，剔除多余的节点和冗余路径，实现路径剪枝优化。

剪枝优化处理步骤为：

a. 获取初始泊车路径节点，基于RS曲线取固定步长在各点间进行插值。

b. 从泊车起始点开始，依次对各插值点以较大半径进行重新布线，且需确保重新布线的路径无碰撞。

c. 提取剪枝后的节点，仍然用RS曲线连接起来生成平滑的泊车路径。

经过剪枝处理后，减少了路径长度和拐点数，但在RS曲线的节点处可能会出现曲率不连续问题。而B样条曲线在平滑路径时不影响路径的基本形态且调用相对简单，因此本文采用三次B样条曲线对泊车路径进行平滑处理。B样条曲线的表达式为：

$$P(t) = \sum_{i=0}^{n} P_i B_{i,k}(t) \quad (16)$$

$$B_{i,k}(t) = \frac{1}{k!}\sum_{j=0}^{k-i}(-1)^j H_{k+1}^{j}(t+k-i-j)^k \quad (17)$$

式中：$P(t)$为B样条曲线函数，t为路径参变量，k为B样条曲线次数，i为控制点索引，j为展开求和索引，$B_{i,k}(t)$为k次B样条基函数。

3.5 算法参数设置

在SPM-Bi-RRT*算法中，斥力影响半径d_0、领域半径r以及RRT*算法重选父节点和重新布线的半径均为$3S$，即3倍的扩展步长。各环节关键参数设置如表2所示。

表2 算法参数设置

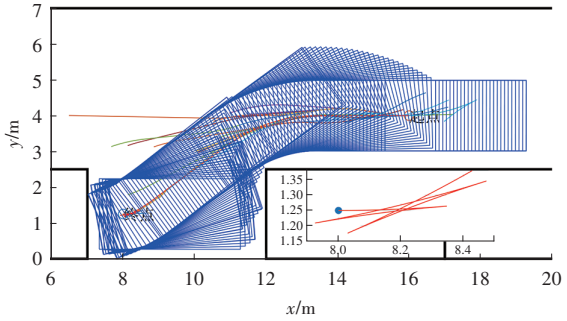
参数符号	参数含义	数值
K_{rep}	斥力系数	8.0
α	邻近点系数	0.8
β	障碍物密度系数	0.26
γ	容错度系数	0.1
S_{base}	基础步长	1.2
S_{max}	最大步长	2.5
S_{min}	最小步长	0.3
ω_0	步长控制系数	0.9
$p_{1\times4}$	惩罚系数	[1, 2, 1.5, 1.2]

4 仿真分析

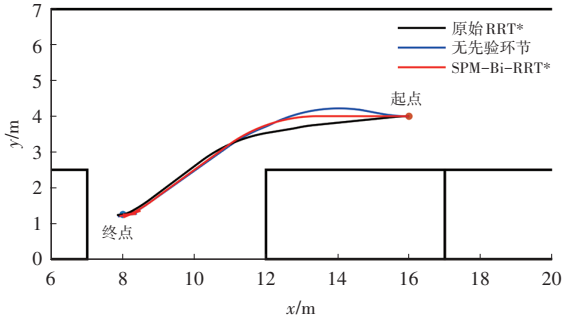
为了验证本文所提出的SPM-Bi-RRT*路径规划方法在复杂泊车场景的适应性和有效性，基于MATLAB构建3种典型复杂泊车场景，并通过仿真分析进行验证。为了消除RRT*算法随机性对结果的影响，确保规划结果的准确性，取10次路径规划结果的平均值作为最终结果。

4.1 狭窄车位泊车场景

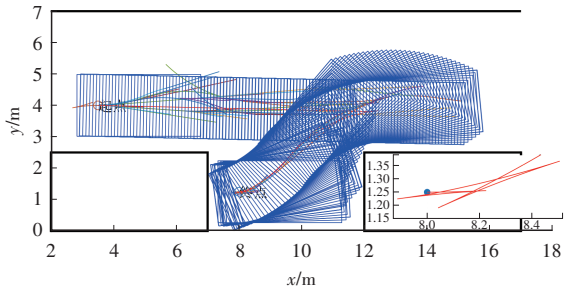
设定狭窄车位泊车场景的车位长为5 m，宽为2.5 m，泊车通道宽为4.5 m，泊车终止点位姿为(8,1.25,0)，讨论车辆从停车位左、右两侧泊入的情况，起始点位姿分别为(16,4,0)和(3.5,4,0)。分别使用不同算法进行仿真验证，其泊车路径规划仿真结果如图7所示。



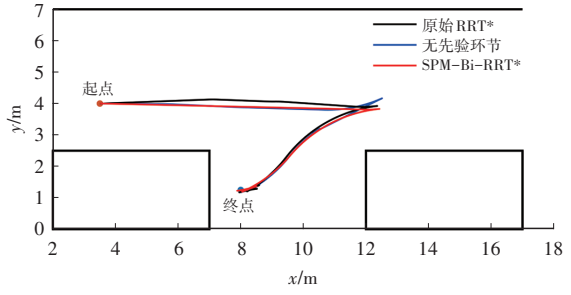
(a)SPM-Bi-RRT*算法路径规划(右侧)



(b)泊车路径对比(右侧)



（c）SPM-Bi-RRT*算法路径规划（左侧）



（d）泊车路径对比（左侧）

图7　狭窄车位泊车路径规划结果

如图7a和图7c所示，本文提出的SPM-Bi-RRT*算法在车位狭窄时需要在库内进行2次位姿调整，确保车辆泊入目标位姿，且泊车起始点位于车位左、右两侧均能实现泊入。图7b和7d为不同算法的路径对比结果，原始RRT*指采样方法为随机目标偏置，无先验环节指仅采用斥力偏置构建概率地图，各算法仅有采样策略的不同，其他环节均保持一致。

狭窄车位平均仿真数据如表3所示，在相同仿真场景下，SPM-Bi-RRT*相比原始RRT*采样次数和节点数量分别减少了328次和3.4个，极大提升了搜索效率，减少了无效节点，平均规划时间减少了56.67%，平均路径长度缩短7.74%，其中位姿调整路径长度缩短13.9%，证明了改进算法在该场景下的有效性和适用性。

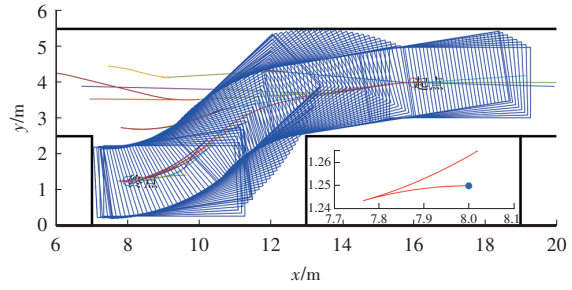
表3　狭窄车位仿真数据

算法	规划时间/s	路径长度/m	采样次数/次	节点数/个
原始RRT*	11.86	11.86	591	8.6
无先验环节	7.29	10.66	347	6.3
SPM-Bi-RRT*	5.14	10.13	263	5.2

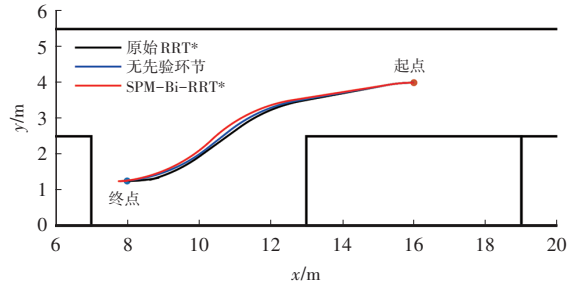
4.2　通道受限场景

设定通道受限泊车场景车位长为6 m，宽为2.5 m，泊车通道受限存在宽度受限和行驶方向受限两种情况，分别设定泊车通道宽度为3 m，或前进方向受限情况，泊车起始点位姿分别为(16,4,0)和(3.5,4,0)，终止点位姿为(8,1.25,0)。分别使用不同算法进行仿真，其泊车路径规划仿真结果如图8所示。

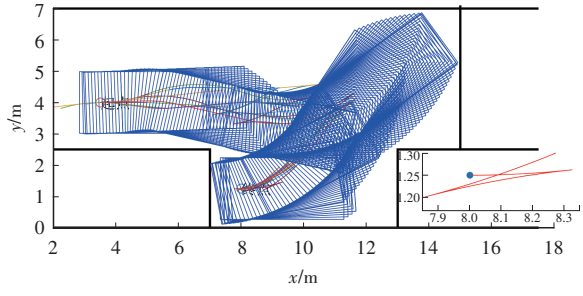
如图8a和8c所示，本文提出的SPM-Bi-RRT*算法在泊车通道长度受限时，可以借助部分车位空间进行姿态调整，确保能够以合适的姿态入库。图8b和8d为不同算法的路径对比结果，原始RRT*路径存在调整路段，路径平滑度差，无先验环节导致路径的转向幅度偏大，SPM-Bi-RRT*算法可以较好地权衡路径长度和转向幅度。



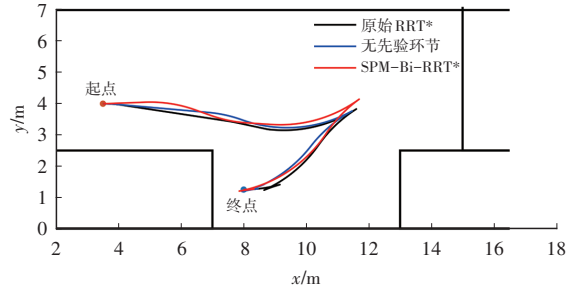
（a）SPM-Bi-RRT*算法路径规划（宽度受限）



（b）泊车路径对比（宽度受限）



（c）SPM-Bi-RRT*算法路径规划（长度受限）



（d）泊车路径对比（长度受限）

图8　通道受限泊车路径规划结果

通道受限平均仿真数据如表4所示，在相同仿真场景下，SPM-Bi-RRT*相比原始RRT*采样次数和节点数量分别减少了325次和3.2个，极大提升了搜索效率，减少了无效节点，平均规划时间减少了49.63%，平均路径长度缩短3.84%，证明了改进算法在该场景下

的有效性和适用性。

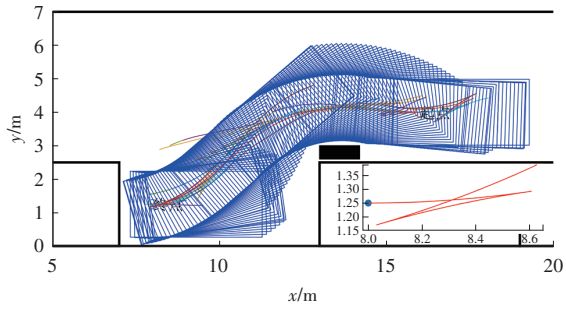
表4　通道受限仿真数据

算法	规划时间/s	路径长度/m	采样次数/次	节点数/个
原始RRT*	10.94	14.32	608	9.0
无先验环节	6.33	14.12	347	6.9
SPM-Bi-RRT*	5.51	13.77	283	5.7

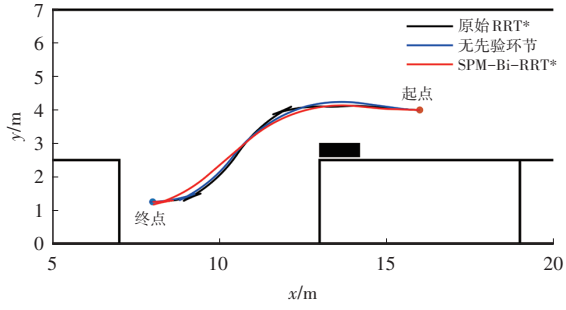
4.3　存在障碍物场景

设定存在障碍物泊车场景车位长为6 m，宽为2.5 m，泊车通道宽为4.5 m。在该场景中，停车位和泊车通道附近存在不同位置和大小的障碍物，泊车起始点位姿(16,4,0)，终止点位姿为(8,1.25,0)。分别使用不同算法进行仿真对比，其泊车路径规划仿真结果如图9所示。

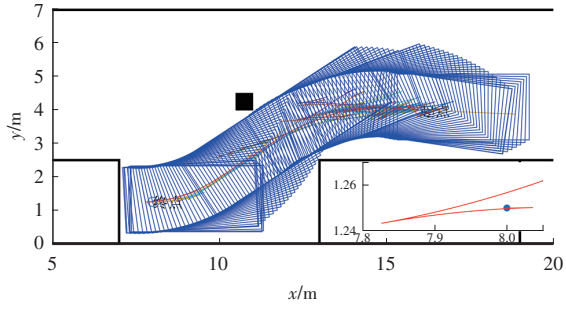
如图9a和9c所示，本文提出的SPM-Bi-RRT*算法在泊车场景中存在障碍物时，可通过一次位姿调整实现绕行，确保车辆无碰撞地泊入目标车位。图9b和9d为不同算法的路径对比结果，原始RRT*路径存在往复冗余路段，且搜索盲目性导致有时无法规划出有效路径，而SPM-Bi-RRT*路径的转向平滑度更好，规划成功率高。



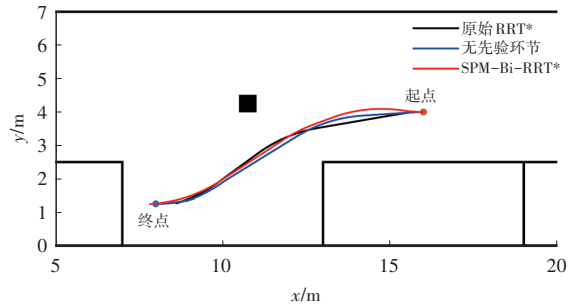
(a)SPM-Bi-RRT*算法路径规划(障碍物1)



(b)泊车路径对比(障碍物1)



(c)SPM-Bi-RRT*算法路径规划(障碍物2)



(d)泊车路径对比(障碍物2)

图9障碍物场景泊车路径规划结果

表5所示为障碍物场景平均仿真数据，在相同仿真场景下，SPM-Bi-RRT*相比原始RRT*采样次数和节点数量分别减少了241次和1.3个，极大提升了搜索效率，减少了无效节点，平均规划时间减少了58.42%，平均路径长度缩短3.65%，其证明了改进算法在该场景下的有效性和适用性。

表5　障碍物场景仿真数据

算法	规划时间/s	路径长度/m	采样次数/次	节点数/个
原始RRT*	10.01	9.37	414	6.2
无先验环节	5.86	9.12	208	5.4
SPM-Bi-RRT*	4.12	9.04	173	4.9

5　结束语

针对复杂泊车场景中自动泊车规划时间长、路径质量欠佳等问题，本文提出了一种基于智能概率地图的双向快速随机搜索树(SPM-Bi-RRT*)的路径规划算法。并以平行泊车为例，在3种复杂泊车场景中进行了仿真验证。结果表明，该算法能够稳定生成安全、高质和高效的规划路径，并在规划时间与路径长度方面均优于RRT*算法，验证了其在复杂泊车场景中的优势，为自动泊车系统的实时路径规划提供了可行的理论支撑和方法参考。

本文在采样策略与路径优化2个层面进行了关键创新：一方面，提出了一种基于概率地图的智能采样机制，通过逐级限制采样区域，引入斥力偏置与先验路径，有效提升了算法在搜索空间中的采样效率；另一方面，通过改进RS曲线的扩展代价并采用自适应动态步长策略，进一步结合剪枝操作与B样条曲线对冗余路径进行优化处理，增强了节点扩展的导向性与收敛速度。该创新有效提高了路径规划的成功率和搜索效率。

参　考　文　献

[1] 胡杰, 朱令磊, 陈瑞楠, 等. 狭小车位平行泊车路径规划方法研究[J]. 汽车工程, 2022, 44(7): 1040-1048.
HU J, ZHU L L, CHEN R N, et al. Research on Parallel

Parking Path Planning Method for Narrow Parking Spaces[J]. Automotive Engineering, 2022, 44(7): 1040-1048.

[2] 刘翀. 基于6次多项式的自动泊车轨迹算法研究[D]. 长春: 吉林大学, 2022.
LIU C. Research on Automatic Parking Trajectory Algorithm Based on Sixth Degree Polyno[D]. Changchun: Jilin University, 2022.

[3] LI B, ACARMAN T, PENG X, et al. Maneuver Planning for Automatic Parking with Safe Travel Corridors: A Numerical Optimal Control Approach[C]// 2020 European Control Conference (ECC). IEEE, 2020: 1993-1998.

[4] 刘平, 陈卓, 刘明杰, 等. 阶段约束下Gauss配点离散化平行车位自动泊车轨迹规划[J]. 汽车工程, 2023, 45(7): 1163-1173.
LIU P, CHEN Z, LIU M J, et al. Gauss Allocation Points Parameterization Parallel Automatic Parking Trajectory Planning for Vehicle under Multi-Stage Constraints[J]. Automotive Engineering, 2023, 45(7): 1163-1173.

[5] 陈晓明, 李柏, 范丽丽, 等. 基于半空间约束理论的自动泊车高性能轨迹优化方法[J]. 机械工程学报, 2024, 60(10): 273-288.
CHEN X M, LI B, FAN L L, et al. High-performance Trajectory Optimization for Automated Parking via Half-space Constraining Theory[J]. Journal of Mechanical Engineering, 2024, 60(10): 273-288.

[6] YANG H, XU X, HONG J. Automatic Parking Path Planning of Tracked Vehicle Based on Improved A* and DWA Algorithms[J]. IEEE Transactions on Transportation Electrification, 2022, 9(1): 283-292.

[7] LIAN J, REN W, YANG D, et al. Trajectory Planning for Autonomous Valet Parking in Narrow Environments with Enhanced Hybrid A* Search and Nonlinear Optimization[J]. IEEE Transactions on Intelligent Vehicles, 2023, 8(6): 3723-3734.

[8] 任秉韬, 王浙浙, 邓伟文, 等. 基于混合A*和可变半径RS曲线的自动泊车路径优化方法[J]. 中国公路学报, 2022, 35(7): 317-327.
REN B T, WANG X X, DEND W W, et al. Path Optimization Algorithm for Automatic Parking Based on Hybrid A* and Reeds-Shepp Curve with Variable Radius[J]. China Journal of Highway and Transport, 2022, 35(7): 317-327.

[9] 秦东晨, 张文灿, 王婷婷, 等. 受限泊车通道下自动驾驶平行泊车的路径规划方法[J]. 郑州大学学报(工学版), 2024, 45(5): 1-7.
QIN D C, ZHANG W C, WANG T T, et al. A Path Planning Method for Parallel Parking in Constrained Parking Channels [J]. Journal of Zhengzhou University (Engineering Science), 2024, 45(5): 1-7.

[10] SHIN S, AHN J, PARK J. Desired Orientation RRT (DO-RRT) for Autonomous Vehicle in Narrow Cluttered Spaces[C]// 2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2016: 4736-4741.

[11] JHANG J H, LIAN F L, HAO Y H. Forward and Backward Motion Planning for Autonomous Parking Using Smooth-feedback Bidirectional Rapidly-Exploring Random Trees with Pattern Cost Penalty[C]// 2020 IEEE 16th International Conference on Automation Science and Engineering (CASE). IEEE, 2020: 260-265.

[12] DING J, ZHOU Y, HUANG X, et al. An Improved RRT* Algorithm for Robot Path Planning Based on Path Expansion Heuristic Sampling [J]. Journal of Computational Science, 2023, 67.

[13] 姚智龙, 张小俊, 王金刚. 改进Bi-RRT*算法的自动泊车路径规划[J]. 机械科学与技术, 2024, 43(6): 1063-1071.
YAO Z L, ZHANG X J, WANG J J. Automatic Parking Path Planning with Improved Bi-RRT* Algorithm[J]. Mechanical Science and Technology for Aerospace Engineering, 2024, 43(6): 1063-1071.

（责任编辑　天下溪）

修改稿收到日期为2026年1月4日。