重塑黏弹性绳路径规划器（RVP）

Sarvesh Mayilvahanan密歇根大学机器人系美国密歇根州安娜堡 smayil@umich.edu

Akshay Sarvesh*Texas A&M University* 电气与计算机工程美国德克萨斯州大学城 sarvesh@tamu.edu

Swaminathan Gopalswamy*Texas A&M University* 机械工程美国德克萨斯州大学城 sgopalswamy@tamu.edu

arXiv:2303.00947v1 [cs.RO] 2 Mar 2023

摘要——**我们提出了重塑黏弹性绳路径规划器（RVP），这是一种路径规划器，可根据机器人车辆对环境的传感器观测，重塑期望的全局规划。我们将路径建模为一条具有保持形状倾向的黏弹性弦，并用一系列相连的弹簧、质量块和阻尼器近似表示。随后，根据障碍物产生的力对合力路径进行重塑，直到达到平衡。由于连接离散质量块的弹簧锚点的作用，重塑后的路径形状仍与原始路径相近。最终路径是弹簧-质量-阻尼器网络的平衡构型。RVP 借助两个关键概念：（i）虚拟障碍物力，推动弹簧-质量-阻尼器系统偏离原始路径；（ii）与弹簧-质量-阻尼器网络协同工作的锚点，以尽力保持路径形状。我们通过仿真展示结果，并将其性能与现有的重塑局部规划器进行比较；该规划器同样接收全局规划，并根据基于传感器的环境观测对其进行重塑。**

索引词—**路径规划、运动规划、动态控制、自主导航、机器人导航**

I. 引言

机器人车辆（*RVs*）的自主移动是一个研究问题，在广泛的应用领域中都备受关注。这些应用包括但不限于：自动驾驶汽车等导航应用、自动驾驶卡车运输和仓库管理。人们也在努力减少人类在某些危险环境中的参与，因为这些环境会危害人们的健康和福祉。其中一些应用包括使用机器人扑灭野火、自主采矿，以及在灾害易发地区开展救援行动 [1]。由于环境的特殊性，以及静态和动态障碍物缺乏结构，机器人的自主导航问题——即一辆遥控车辆从环境中的某个位置出发，并接受导航至终点的任务——往往仍然难以解决。其他应用还包括机器人机械臂领域，其应用范围广泛，从医疗领域的机器人辅助手术到零售领域的叠衣服。这些应用都要求机器人在避开障碍物的同时，按照预期配置进行精准导航。

本研究部分由美国陆军研究实验室通过资助项目 W911NF1920243 提供支持。

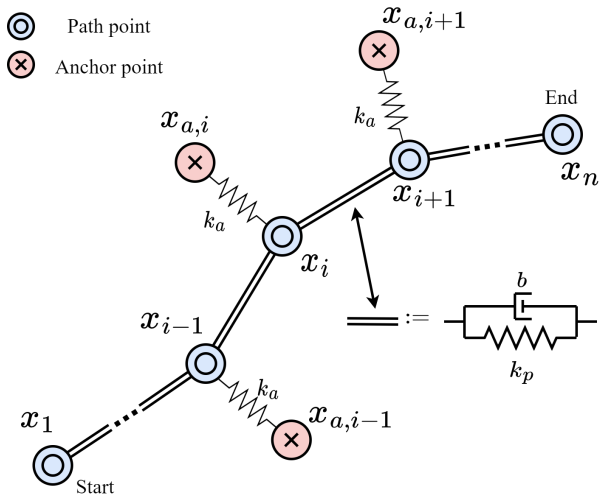


图 1. *RVP* 系统中路径点（蓝色）和锚点（红色）的表示。路径点 x_i 是局部路径的离散表示，并通过弹簧和阻尼器与相邻路径点相连，而锚点 $x_{a,\ i}$ 则通过弹簧与各自对应的路径点相连。

机器人车辆的自主导航可分为两大类：经典技术和基于学习的技术，综述论文 [2]对此进行了讨论。

经典技术依靠将自主导航问题分解为两个主要部分：(i) 感知和 (ii) 导航。在感知方面，遥控车辆使用本体感受传感器和外感受传感器来获取周围环境信息，并确定自身在环境中的位置。导航还可进一步分为三个部分：(a) 路径规划：通常将较高层次的抽象任务转换为遥控车辆需要行驶的目标路径。(b) 运动规划将这一高层规划转换为一系列运动基元，供遥控车辆执行。(c) 动态控制将运动基元转换为低层执行器指令，例如加速度、方向盘转角输入等。经典技术通常依赖上述各部分的模型，并进行一系列优化，以实现自主导航，沿期望轨迹行驶并避开障碍物。本研究属于经典技术这一类别。

基于学习的技术通常采用数据驱动模型，利用学习表征制定策略

这些技术可以替代其中一个组件（或所有组件，例如感知、运动规划、路径规划和动态控制）。基于学习的技术的优点包括减少建模工作，但通常也因此缺乏可解释性。

[3] 提出了概率路线图方法（PRM），这是一种基于采样的技术。 [4] 利用PRM技术，为三维工作空间构建了基于障碍物的PRM，这是最早将该技术用于运动规划的方法之一。 [5] 提出了快速探索随机树（RRT），由此衍生出RRT*等变体 [6]。

这类抽象可与基于图的范式结合，形成粗略全局规划器，例如：Dijkstra最短路径算法 [7] 和基于启发式的A*搜索算法 [8]。D* Lite [9] 是A*算法的另一种优化版本，它通过使用智能数据结构来提高更新速度并节省计算周期，从而避免重新规划。

局部规划器通常会生成一系列更精细的航路点和/或低级指令，并将其直接发送给控制器，以执行基于较短视野的航路点跟踪。与全局规划器不同，局部规划器需要考虑机器人周围的局部特征，例如：障碍物、梯度等。局部规划器是一种在线算法，需要根据眼前的视野快速做出决策。

势场方法（PFM）首次在[10]中提出。该算法假设目标点生成一个势场，其梯度朝向目标变化，从而产生指向目标的吸引力。此类技术可能会陷入由势场产生的局部极小值，导致遥控车辆停滞不前。 [11] [12] [13] [14] [15] 展示了对现有算法的优化，以解决停滞问题，但这些方法大多仅适用于特殊条件。

在已知车辆动力学和所观测环境的情况下，主动探索方法（*AEM*）（例如滚动时域模型预测控制（MPC）技术）已被用于解决在线优化问题，以实现导航 [16] [17] [18]。此类技术既可用于生成低层控制指令，也可用于生成导航路径。 [16]采用配备环视摄像头的MPC控制器，以移动目标的方式执行导航和避障。部分可观测马尔可夫决策过程（*POMDP*）技术也可用于此目的 [19] [20]。主动探索方法（AEM）通常针对时间范围优化总体代价。除非进行优化以避免较大的搜索空间，否则主动探索方法（AEM）的计算成本很高。

[21] 提出了重塑局部路径规划器，该规划器基于路径感知矩场创建局部路径。它克服了 PFM 的缺点，避免了停滞问题，并通过优化动作搜索空间，比 AEM 在计算上更加高效。

经典技术虽然取得了成功，但要通过建模和设计出适用于各种场景的最佳局部规划器，仍需要投入大量工程工作。通常——传统技术通常需要大量建模，这可能难以实现。为了减少工程工作量，文献中提出了采用机器学习的数据密集型技术。许多研究从不同角度探讨了这一问题。根据综述论文 [2]，，基于学习的导航技术可分为三类：(i) 学习整个导航栈，(ii) 学习导航子系统，(iii) 学习单个组件。下面列出一些与本研究相关的基于学习的规划器 [17] [22] [23] [24]。

在功能上，重塑黏弹性绳路径规划器（RVP）与弹性带规划器（EBP） [25]相似。EBP 通过沿着全局路径前进，逐步更新并优化局部路径。弹性带会发生变形，其形状和构型会根据全局路径上的内部收缩力以及路径周围障碍物产生的外部排斥力而改变，从而消除路径中的任何松弛。在本文中，RVP 与重塑局部路径规划器 [21],进行了比较，后者同样是一种基于环境的传感器观测来重塑给定全局规划的规划器。

其他方法（如 EBP）采用能够扩展和收缩局部路径的虚拟力，而重塑黏弹性绳路径规划器则加入了若干关键要素，以产生稳定且理想的结果。在弹簧-质量-阻尼器网络中使用阻尼器，可使路径针对（i）虚拟障碍物力的反应更加平稳。此外，系统中的（ii）锚点 有助于保持期望全局路径的形状，并为路径曲率提供关键支撑。

II. 初步定义

1) 运行区域 Ω： 将算法的运行区域表示为二维区域 Ω，其上定义有高度、表面摩擦等属性。

2) 期望全局路径 $\mathbf{x}^{dGP}$： 我们假设上游全局路径规划器 已确定一条期望全局路径，该路径由一系列 n_{GP} 个点 $\mathbf{x}^{dGP} = \{x_i\},\ \ x_i \in \Omega, i = \{1, ..., n_{GP}\}$ 给出。假设此类期望全局路径是基于静态或过时信息生成的。此外，还将通过计算沿路径的距离，从$\mathbf{x}^{dGP}$ 推导出期望全局路径的距离参数化：$\mathbf{s}^{dGP} = \{s_i^{dGP} = ||x_{i+1}^{dGP} - x_i^{dGP}||\} \forall i = \{1, ..., n_{GP} - 1\}$，。$s_1^{dGP} = 0$

3) 感知环境 $\mathbf{x}^{\epsilon}$： 假设车辆上的所有传感器均已处理，以生成一组n_ϵ 点 $\mathbf{x}^{\epsilon} = \{x_i\},\ \ x_i \in \Omega_\epsilon \subset \Omega,$ $i = \{1, ..., n_\epsilon\}$。每个点都关联一个属性函数 $\epsilon(x) : \Omega_\epsilon \to [0, c]$，其中某个正常数 c。实际应用中，这种属性映射可以将 Ω_ϵ 映射为整数，也可以仅映射为布尔值；此时它定义了一个简单的占据栅格地图。感知环境在每个控制采样时生成，并被视为最新信息。本文假设感知环境已纳入感知信息中的不确定性，并将其视为对环境的最佳估计。

4）局部路径 $\mathbf{x}^{lP}$：本文主要算法的输出是一系列 n_{lP} 点 $\mathbf{x}^{lP}=\{x_i\}$，$x_i\in\Omega, i=\{1,\ldots,n_{lP}\}$，使得存在一条相应的光滑曲线 $\bar{}\mathbf{x}^{lP}(s)$：$[0,s_{lP}]\to\Omega$，以及一个单调序列 $\mathbf{s}^{lp}=\{s_i\}$，$s_i\in[0,s_{lP}]$ 满足 $\bar{}\mathbf{x}^{lP}(s_i)=\mathbf{x}^{lP}[i]$。此外，该曲线应足够光滑，以便在局部路径的每一点都能定义曲率；也就是说，存在定义良好的曲率函数 $\bar{\kappa}^{lP}$：$[0,s_{lP}]\to\Re$，并据此将序列 κ^{lP}定义为 $\bar{\kappa}^{lP}(s_i)=\kappa^{lP}[i]$。路径长度为 $p_{lP}:=s_{n_{lP}}$

5) 锚点 $\mathbf{x}^a$：弹簧-质量-阻尼器系统的建模涉及一组锚点 $\mathbf{x}^a=\{x_{a,i}\}\in\Omega$，$i\ \{1,\ldots,n_{lP}-2\}$ 它们分别对应于除起点和终点之外的各个局部路径点 $x_i\in\mathbf{x}^{lP}$。这些锚点保持路径的曲率，并将局部路径系连到全局路径。每个锚点 $x_{a,\ i}$ 弹簧都有一个弹簧长度$l_{a,\ i}$。

6) 弹簧-质量-阻尼器系统：黏弹性绳路径 $\mathbf{x}^{lP}$ 由质量为 m 的点质量组成。弹簧常数和阻尼常数由两个调节常数 ω 和 ζ 定义：路径点之间的弹簧常数 $k_p:=m\omega^2$，锚点之间的弹簧常数 $k_a:=ck_p$，以及阻尼常数 $b:=2m\zeta\omega$。其中，c 是一个缩放参数，表示 k_a 相对于 k_p 的刚度。弹簧长度 $l_{j,\ k}$ 是两点之间的初始弹簧长度$x_j,\ x_k\in\Omega$。

7) 横向偏差 e^P：给定一条路径$\mathbf{x}^P$ 和一个点$y\in\Omega$，横向偏差 $e^P(y)$是 y 到该路径的最短距离，计算方式为 $||y\vec{y}_\perp||$，其中点 $y_\perp$ 位于$\mathbf{x}^P$ 上，该点处路径的切线为$\hat{}\ t_{y_\perp}$，且满足 $y\vec{y}_\perp\perp\hat{}t_{y_\perp}$。

8) 路径偏差 $\Delta P(\mathbf{x}^1,\mathbf{x}^2)$：给定两条路径$\mathbf{x}^1$和$\mathbf{x}^2$，，路径偏差是横向偏差的平方的累积和：$\Delta P(\mathbf{x}^1,\mathbf{x}^2):=\sum_{x_i}e^2(x_i)\quad\forall x_i\in\mathbf{x}^1$

9) 碰撞 $\delta_c(x^P,\ x^\epsilon)$：给定感知环境$\mathbf{x}^\epsilon$中的一条路径 $\mathbf{x}^P$，我们将布尔碰撞函数 δ_c定义为：如果路径与任一障碍物发生碰撞，则为真，否则为假。具体而言，我们定义 $\delta_c=(||x_i^P,\ x_j^\epsilon||)>d_c,\quad\forall x_i^P\in\mathbf{x}^P,\ x_j^\epsilon\in\mathbf{x}^\epsilon$，其中 d_c 是一个阈值距离，用于判断路径是否过于靠近障碍物。

A. 问题陈述

给定期望全局路径：$\mathbf{x}^{dGP}$，问题目标是合成一条长度为 l_{lP} 的局部路径 $\mathbf{x}^{lP}$，使其不存在碰撞，即 $!\delta_c$，并使路径偏差 $\Delta P(\mathbf{x}^{lP},\mathbf{x}^{dGP})$ 最小化。

$$f_{\text{RVP}}:\mathbf{x}^{dGP}\times\Omega\to\mathbf{x}^{lp}\tag{1}$$

III. 重塑黏弹性弦规划器

此处介绍的局部路径规划器采用自适应黏弹性路径的概念，该路径会根据施加的虚拟力改变形状。这些虚拟力取决于周围的障碍物及与障碍物的距离，这些信息由感知环境 $\mathbf{x}^\epsilon$ 表示。对于此实现方式中，自适应路径由一组点质量构成，并通过弹簧和阻尼器依次连接，如图 1 所示。这种结构可确保各路径点协同移动，彼此相邻的点会相互影响。此外，路径点还通过另一组弹簧连接到一组锚点 $\mathbf{x}^a$，从而锚定在期望全局路径上。这些锚点将路径点系留在原始路径上，确保合力路径与期望全局路径相似，并保持预期的曲率。

路径点 $x_i\in\mathbf{x}^{lP}$ 是表示运行区域 Ω 内路径的点集。这些路径点的运动可由常微分方程（ODE）（2）表示。

$$m\frac{d^2x_i}{dt^2}+b\frac{dx_i}{dt}=F_{p,i}+\int_r\int_\theta F_{o,i}(r,\theta)\tag{2}$$

作用于路径点的虚拟力有两种：基于路径的力$F_{p,\ i}$ 和基于障碍物的力 $F_{o,\ i}$。

A. 力

1）路径力：基于路径的力 $F_{p,\ i}$ 是通过连接弹簧，由相邻路径点 x_{i-1} 和 x_{i+1}作用于点 $x_i\in\mathbf{x}^{lP}$ 的力，此外还包括锚点通过点 $x_{a,\ i}\in\mathbf{x}^a$施加的力。该力根据公式（3）计算。

$$\begin{aligned}F_{p,i}=k_p(x_{i-1}-x_i-l_{i,i-1})+k_p(x_{i+1}-x_i-l_{i,i+1})\\+k_a(x_{a,i}-x_i-l_{a,i})\end{aligned}\tag{3}$$

其中，k_p 是路径点之间的弹簧常数，k_a 是锚点施加的弹簧常数，l 是弹簧长度。

a）锚点位置：在仿真的初始步骤，通过求解公式（4）计算锚点的位置 $x_{a,\ i}\in\mathbf{x}^a$，即与点 $x_i\in\mathbf{x}^{lP}$相对应的锚点位置。该点 $x_{a,\ i}$ 使各种弹簧力达到平衡。锚点 $\mathbf{x}^a$ 用于保持路径的初始曲率，并为局部路径提供作用力，使其保持期望全局路径的形状，从而促使路径维持不变。

$$\begin{aligned}0=k_p(x_{i-1}-x_i-l_{i,i-1})\\+k_p(x_{i+1}-x_i-l_{i,i+1})+k_a(x_{a,i}-x_i)\end{aligned}\tag{4}$$

$$l_{a,i}=d(x_{a,i},x_i)\tag{5}$$

2）障碍物力：障碍物力 $F_{o,\ i}(r,\ \theta)$ 是障碍物在距离 r、角度 θ处作用于点 x_i 的力。该力根据分段函数（6）计算。

$$F_{o,i}(r,\theta)=\begin{cases}a_2\cdot\delta_{\mathbf{x}^\epsilon}(x_i,r,\theta)\cdot\frac{1}{r^n} & r\le a_1\\ a_2\cdot\exp\left(\frac{-(r-a_1)}{a_3}\right)\cdot\delta_{\mathbf{x}^\epsilon}(x_i,r,\theta)\cdot\frac{1}{r^n} & r>a_1\end{cases}\tag{6}$$

在半径 a_1 范围内，障碍物力按定义作用；超出该范围后，力会指数衰减，衰减程度受调节常数 a_3 影响。障碍物力

与路径点和障碍物之间的距离 r 的 n 次方成反比。该力还会乘以调节常数 a_2 进行缩放。给定感知环境 $\mathbf{x}^\epsilon$，定义布尔函数 $\delta_{\mathbf{x}^\epsilon}(x_i, r, \theta)$：如果距离 r 、方向角为 θ 的点（相对于点 x_i ）在感知环境$\mathbf{x}^\epsilon$ 中被占据，则函数值为真，否则为假。该函数确保只有当距离为 r 、角度为 θ 处存在障碍物时，力才会作用于路径点。

障碍物力随距离r 变化的曲线如图 2 所示。

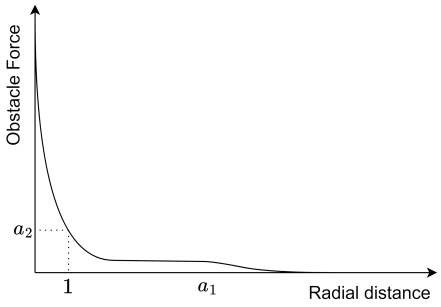


图 2. 障碍物力随径向距离 r 的变化，其中调节参数为 a_1, a_2。

距离障碍物较近时，作用力非常大，并且由于其与距离r成反比而迅速减小。超过截断距离 a_1后，作用力会衰减，最终变得可以忽略不计。这确保了距离路径点较远的障碍物几乎不会产生作用力。

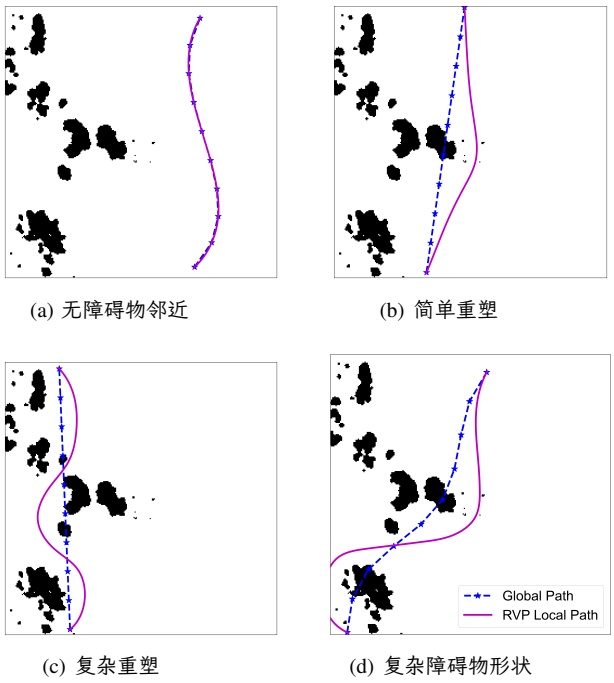
B. 合力路径

RVP 会对路径点的运动进行近似模拟，直至达到积分时间 t_f；这也可以像算法1那样用最大步数表示。如果系统检测到路径点 $\mathbf{x}^{lP}$ 在达到 t_f之前已进入稳态，就会自动退出仿真以降低计算开销。如果所有路径点的加速度都低于某个阈值 a_t，则认为系统已达到稳态： $\forall x \in \mathbf{x}^{lP}$, $\ddot{x} < a_t$。

到达路径的最终状态后，会对路径点进行样条拟合，并通过插值生成一组间距均匀的点，这些点即为重塑黏弹性绳路径规划器的输出。

路径规划器主要根据其在各种场景下提供安全且稳定路径的能力进行评估。在图3中，研究人员基于从Texas A&M University的RELLIS校区一处废弃采石场获取的真实非结构化感知环境激光雷达数据，结合四条不同的全局路径对重塑黏弹性绳路径规划器进行了评估。这些难度各异的示例突出了该规划器能够处理的广泛场景。

在图3(a)中，全局路径并未靠近任何障碍物。因此，规划器生成的重塑路径不会受到障碍物施加的任何力，并且由于锚点使系统保持平衡，路径点之间仍维持原始路径。在图3(b)中，存在



(a) 无障碍物邻近　(b) 简单重塑

(c) 复杂重塑　(d) 复杂障碍物形状

图 3. *RVP* 在真实非结构化环境数据的四种场景下的性能。全局路径以蓝色虚线表示，重塑后的局部路径以洋红色实线表示。*(a)* 展示了期望全局路径未与任何障碍物近距离接触时 *RVP* 的输出。*(b)* 展示了单个障碍物阻挡期望全局路径时 *RVP* 的输出。*(c)* 和 *(d)* 展示了日益复杂的场景，其中多个障碍物与期望全局路径重叠，因此需要进行大量重塑以避开障碍物。

有一个障碍物阻挡了全局路径，导致路径向外推移。然而，路径力确保重塑后的路径不会偏离全局路径太远。在图3(c)中，全局路径必须经过大幅重塑，才能穿过两个关键区域。障碍物力与路径力达到平衡后，路径点能够在障碍物之间移动并达到稳态。图3(d)展示了另一个例子：全局路径必须进行显著调整，尤其是左下方形状奇特的障碍物所致。规划器生成了一条避开所有障碍物、能够应对复杂障碍物的路径。

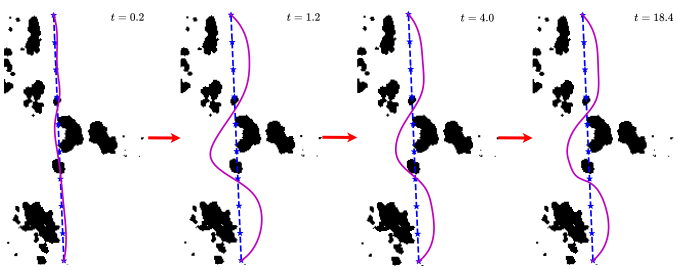


图 4. 图 *3(c)* 场景中，在不同积分时间步下动态重塑的局部路径可视化。全局路径以蓝色虚线表示，局部路径的当前状态以洋红色实线表示。

图4展示了重塑过程中的若干积分时刻下重塑后的局部路径 $0 < t < t_f$。开始时，路径点 $x_i \in \mathbf{x}^{lP}$ 最初受到障碍物力的作用而向外推移。在第二个积分时间步，路径点的偏离达到最大，随后路径力在第三个积分时间步将路径点拉回初始路径。经过一些调整后，由于系统阻尼的作用，局部路径最终达到不受障碍物阻挡的稳态。局部路径的这种动态移动表明，所提出的路径规划器能够适应各种路径和感知环境。

C. 规划器流程

算法1概述了该规划器使用离散方法求解时的内部工作原理。在模拟路径点运动的每一步中，都会计算路径力和障碍物力，并结合动力学推进仿真。

算法1 重塑黏弹性绳路径规划器

数据： $\mathbf{x}^{dGP}$：期望全局路径；$\mathbf{x}^{\epsilon}$：感知环境；
ω，ζ：系统参数；a_1，a_2：障碍物力参数-值，p_{min}：用于仿真的最小步数比例
结果： $\mathbf{x}^{lP}$：局部 path
$\mathbf{x}^{lP} \leftarrow \mathbf{x}^{dGP}$
$k_p\ k_a, b \leftarrow f(\omega, \zeta)$
初始化锚点和弹簧长度
步长 $\leftarrow 1$
当 步长 $<$ 最大步数 **执行**
  $F_p \leftarrow$ 路径力 $\forall x_i \in \mathbf{x}^{lP}$
  $F_o \leftarrow$ 障碍物力 $\forall x_i \in \mathbf{x}^{lP}$
  $\mathbf{x}^{lP} \leftarrow$ 步进动力学$(\mathbf{x}^{lP}, F_p, F_o)$
  如果 路径停滞$(\mathbf{x}^{lP})$ **则**
    路径扰动$(\mathbf{x}^{lP})$ ▷扰动停滞路径点
  end
  如果 步数达到 $> p_{min} \cdot$ 最大值且状态稳定$(\mathbf{x}^{lP})$ **则**
    返回 $\mathbf{x}^{lP}$ ▷ 路径已达到稳态
  end
end
返回 $\mathbf{x}^{lP}$

该规划器还解决了类似势场方法中常见的问题，例如陷入局部极小值，这可能导致路径停滞在不理想的位置。函数 *path stagnated*和*perturb path* 用于识别陷入障碍物内部局部极小值的路径点（表示发生碰撞），并对其进行扰动。该扰动结合相邻路径点产生的路径力，能够将停滞的路径点拉入更有利的位置。

此外，该系统会根据用户定义的变量 p_{min} 仿真最小步数。如果系统表明路径在完成这些最小步数后已达到稳定稳态解，则无需进一步仿真，并返回该路径。这样做是为了在相对简单重塑的情况下节省计算时间。

D. 迭代仿真

路径在仿真的单次迭代后并不总能达到安全状态，因此可能需要多次迭代。每次迭代后，都会对路径进行碰撞评估。如果评估判定路径是安全的，则返回新路径。否则，将不安全的路径作为下一次迭代的初始路径，以获得更安全的路径。每次后续迭代都会对系统参数施加衰减，以确保后续迭代不会大幅改变前几次迭代产生的变化。由于算法参数会衰减，如果需要超过指定次数的迭代才能获得安全路径，则退出仿真，并将该路径标记为不安全。

算法 2迭代 RVP

数据： $\mathbf{x}^{dGP}$：期望全局路径；$\mathbf{x}^{\epsilon}$：感知环境；
ω，ζ：系统参数；a_1，a_2：障碍物力参数-量；λ：参数衰减；d_c：安全裕度
结果： $\mathbf{x}^{lP}$：局部路径；标志：（1：安全，0：不安全）
$\mathbf{x}^{lP} \leftarrow \mathbf{x}^{dGP}$
迭代 $\leftarrow 1$
当 $\delta_c(\mathbf{x}^{lP}, \mathbf{x}^{\epsilon}, d_c)$ **时执行**
  $a_1 \leftarrow a_1 \cdot \lambda^{\text{iteration}-1}$
  $a_2 \leftarrow a_2 \cdot \lambda^{\text{iteration}-1}$
  $\mathbf{x}^{lP} \leftarrow$ RVP($\mathbf{x}^{lP}$, $\mathbf{x}^{\epsilon}$, ω, ζ, a_1, a_2)
  如果迭代 $=$最大迭代次数 **则**
    返回 $\mathbf{x}^{lP}$, 0 ▷局部路径标记为不安全
  end
  迭代 $\leftarrow$ 迭代 $+1$
end
返回 $\mathbf{x}^{lP}$, 1 ▷ 局部路径无碰撞

1) 路径评估：每次迭代都会使用布尔碰撞函数$\delta_c(\mathbf{x}^{lP}, \mathbf{x}^{\epsilon}, d_c)$评估合力路径是否发生碰撞。该函数取决于感知环境$\mathbf{x}^{\epsilon}$ 和安全距离阈值 d_c。

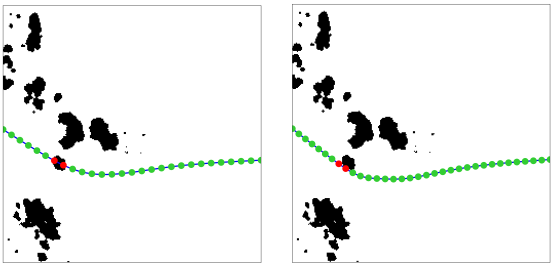
碰撞函数 δ_c 会在 $\forall x_i \in \mathbf{x}^{lP}$ 以及点 x_i与$\mathbf{x}^{\text{itp}}$之间插值生成的其他点处进行评估，这些点构成集合$\mathbf{x}^{\text{eval}} := \mathbf{x}^{lP} \cup \mathbf{x}^{\text{itp}}$。如果某次迭代结束时的路径被判定为不安全（$\delta_c =$true），则将点集$\mathbf{x}_{\text{add}} := \{x_i^e | \forall x_i^e \in \mathbf{x}^{\text{eval}},\ x_j^{\epsilon} \in \mathbf{x}^{\epsilon},\ ||x_i^e,\ x_j^{\epsilon}|| > d_c\}$ 插入路径，供仿真的下一次迭代使用；路径$\mathbf{x}^{lP}_{\text{iter}=n+1} := \mathbf{x}^{lP}_{\text{iter}=n} \cup \mathbf{x}_{\text{add}}$则用作下一次迭代的初始路径。

图 5 展示了这一迭代仿真的过程：经过数次迭代后，路径最终达到稳定安全状态，并通过了所有安全要求。评估点已显示出来，并根据其基于一组 d_c 值测得的安全性进行着色。

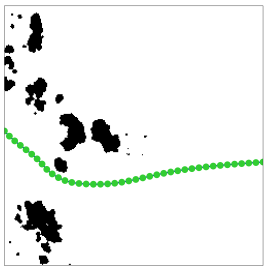
IV. 结果

A. 规划器验证

为了展示 RVP 的能力，我们在随机生成的感知环境和



(a) 迭代 *1*　(b) 迭代 *2*



(c) 迭代 *3*

图 5. 给定路径和 d_c 的模型评估过程。感知环境 $\mathbf{x}^{\epsilon}$ 由黑色障碍物表示。若评估点被判定为安全且无碰撞 ($!\delta_c$)，则标记为绿色；若不安全(δ_c)，则标记为红色。

全局路径上进行了仿真验证。我们生成了一个涵盖大量场景的数据集，覆盖了各种难度下多种可能的路径-障碍物配置。

1）数据集：生成随机场景始于一个随机感知环境。感知环境最初是一个空的占据栅格，随后将随机数量的物体依次放置到地图中。这些物体具有多种形状和尺寸，代表了非结构化环境中常见的障碍物，如灌木和树木。创建感知环境后，生成一条随机全局路径。随机路径的分布涵盖了广泛的场景，包括起点和终点之间的直线路径，以及可能与物体相交的极度弯曲路径。数据集中感知环境和路径的多样性使得能够对规划器进行严格测试。图 6 展示了一个示例场景，其中包含大量物体和一条随机期望全局路径。

2）性能：在包含 10，000 个场景的数据集上评估重塑黏弹性绳路径规划器后，我们发现其成功率为 **94。3%**。此处，成功率定义为：在给定感知环境 $\mathbf{x}^{\epsilon}$ 的情况下，局部路径 $\mathbf{x}^{lP}$ 沿整条路径均无碰撞，即 $!\delta_c(\mathbf{x}^{lP}, \mathbf{x}^{\epsilon})$。

B. 重塑黏弹性绳路径规划器（*RVP*）与重塑局部路径规划器（*RLP*）的对比场景

我们在图 7 中通过一个类似的现有局部规划器 [21]，即重塑局部路径规划器 *(RLP)*，展示了 RVP 的工作原理。[21] 同样会在存在障碍物时，利用路径无关转向力矩重塑给定的全局规划。在 RLP 的情况下，可以看到遥控车辆从远离全局路径起点的位置开始。两者

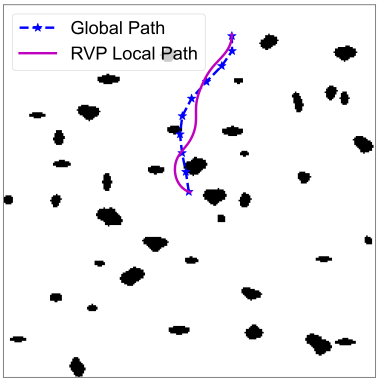
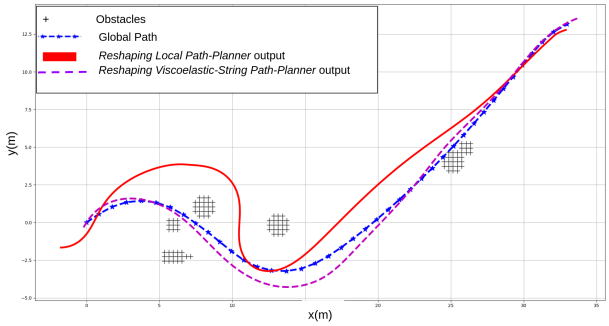
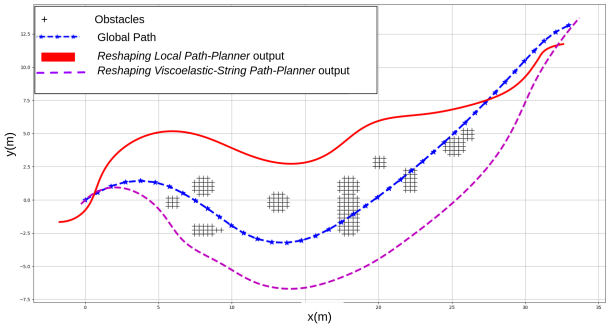


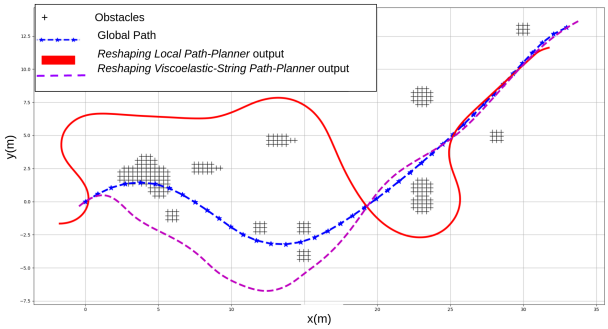
图 6。随机生成的感知环境及期望全局路径示例，以及与之对应的 *RVP* 重塑局部路径。



(a)



(b)



(c)

图 7。在 *3* 种非结构化环境中，沿非直线期望全局路径对比重塑局部路径规划器与重塑黏弹性绳路径规划器。

RLP 和 RVP 都具有能够覆盖期望全局路径整个长度的前视范围。

在图7(a)和图7(c)中，RVP 在使路径偏差较小、即 $\Delta P(\mathbf{x}^{dGP}, \mathbf{x}^{lP})$，从而贴近期望全局路径方面，明显优于 RLP。在图7(b)中，由于特定的路径—障碍物配置，两种规划器的性能相当。总体而言，RVP 的表现至少不逊于 RLP，这得益于整个路径能够同时重塑，以及系统内置的稳定性。

V. 结论与未来工作

本文介绍了一种新颖的路径重塑规划器，它基于两个关键概念重塑期望全局路径：(i) 作用于路径点质量块的虚拟障碍物力；(ii) 弹簧-质量-阻尼器系统和锚点，它们能使生成的局部路径保持平滑的曲率和稳定性。

此外，RVP 的结果也通过一个更大的随机生成的数据集进行了验证，并与一种类似的路径重塑规划器进行了定性比较。

重塑黏弹性绳路径规划器的主要缺点是近似公式 (2) 中常微分方程的计算开销较大。为解决这一问题，我们提出使用 RVP 求解的场景数据集训练神经网络，以实现实时性能。我们已在使用软演员评论家模型 [26] 和近端策略优化模型 [27] 结合专门设计的奖励函数学习该常微分方程方面取得了一些初步进展。

参考文献

[1] R. R. Murphy，灾害机器人学。MIT出版社，2014年。[2] X. Xiao、B. Liu、G. Warnell 和 P. Stone，《运用机器学习进行移动机器人导航的运动控制：综述》，2020年。[3] L. E. Kavraki、P. Svestka、J. . Latombe 和 M. H. Overmars，《高维构型空间中用于路径规划的概率路线图》，*IEEE*机器人与自动化汇刊，第12卷，第4期，第566–580页，1996年。[4] N. M. Amato 和 Y. Wu，《用于路径与操作规划的随机路线图方法》，载于*IEEE*机器人与自动化国际会议论文集，第1卷。IEEE，1996年，第113–120页。[5] S. M. LaValle，《快速探索随机树：一种路径规划新工具》，1998年。[6] S. Karaman 和 E. Frazzoli，《用于最优运动规划的基于采样的算法》，2011年。[7] E. W. Dijkstra等，《关于图的两个问题的注记》，数值数学，第1卷，第1期，第269–271页，1959年。[8] P. E. Hart、N. J. Nilsson 和 B. Raphael，《最小代价路径启发式确定的形式基础》，*IEEE*系统科学与控制论汇刊，第4卷，第2期，第100–107页，1968年。[9] S. Koenig 和 M. Likhachev，《Dˆ* lite》，*AAAI/IAAI*，第15卷，2002年。[10] O. Khatib，《机械臂与移动机器人的实时避障》，国际机器人研究期刊，第5卷，第1期，第90–98页，1986年。 [在线]。可访问：https://doi.org/10.1177/027836498600500106[11] L. Shangguan、J. A. Thomasson 和 S. Gopalswamy，《自动驾驶粮食运输车的运动规划》，*IEEE*车辆技术汇刊，第70卷，第3期，第2112–2123页，2021年。[12] T. Weerakoon、K. Ishii 和 A. A. F. Nassiraei，《一种基于人工势场的移动机器人导航方法，用以防止陷入死锁》，人工智能与软计算研究期刊，第5卷，第3期，第189–203页，2015年。[13] J. Lee、Y. Nam、S. Hong 和 W. Cho，《采用势场法和随机力算法的新势函数》，智能与机器人系统期刊，第66卷，第3期，第303–319页，2012年。

[14] F. Bounini、D. Gingras、H. Pollart 和 D. Gruyer，《用于在线路径规划应用的改进人工势场法》，载于*2017*年*IEEE*智能车辆研讨会（*IV*）。IEEE，2017年，第180–185页。[15] Q. Zhu、Y. Yan 和 Z. Xing，《结合模拟退火的人工势场方法机器人路径规划》，载于第六届智能系统设计与应用国际会议，第2卷，2006年，第622–627页。[16] N. Hirose、F. Xia、R. Martin-Martin、A. Sadeghian 和 S. Savarese，《用于导航的深度视觉模型预测控制策略学习》，*IEEE*机器人与自动化快报，第4卷，第3184–3191页，2019年10月。[17] Y. Pan、C.-A. Cheng、K. Saigol、K. Lee、X. Yan、E. Theodorou 和 B. Boots，《运用端到端深度模仿学习实现敏捷自动驾驶》，2019年。[18] J. Ji、A. Khajepour、W. W. Melek 和 Y. Huang，《基于具有多重约束的模型预测控制的车辆碰撞规避路径规划与跟踪》，*IEEE*车辆技术汇刊，第66卷，第2期，第952–964页，2017年。[19] J. Zhang、J. T. Springenberg、J. Boedecker 和 W. Burgard，《利用后继特征进行深度强化学习，实现跨相似环境导航》，2017年。[20] O. Zhelo、J. Zhang、L. Tai、M. Liu 和 W. Burgard，《运用深度强化学习进行好奇心驱动的无地图导航探索》，2018年。[21] A. Sarvesh、A. Carroll 和 S. Gopalswamy，《重塑局部路径规划器》，*IEEE*机器人与自动化快报，第7卷，第3期，第6534–6541页，2022年。[22] S. Siva、M. Wigness、J. Rogers 和 H. Zhang，《通过联合表征与学徒学习使机器人适应非结构化地形》，载于机器人学：科学与系统（*RSS*），2019年。[23] U. Muller、J. Ben、E. Cosatto、B. Flepp 和 Y. L. Cun，《通过端到端学习实现越野障碍规避》，载于神经信息处理系统进展。Citeseer，2006年，第739–746页。[24] M. Wigness、J. G. Rogers 和 L. E. Navarro-Serment，《从人类示范中学习机器人导航：学习控制行为》，载于*2018*年*IEEE*机器人与自动化国际会议（*ICRA*）。IEEE，2018年，第1150–1157页。[25] S. Quinlan 和 O. Khatib，《弹性带：连接路径规划与控制》，载于 *[1993] IEEE*机器人与自动化国际会议论文集。IEEE，1993年，第802–807页。[26] T. Haarnoja、A. Zhou、P. Abbeel 和 S. Levine，《软演员-评论家：采用随机演员的离策略最大熵深度强化学习》，载于国际机器学习会议。PMLR，2018年，第1861–1870页。[27] J. Schulman、F. Wolski、P. Dhariwal、A. Radford 和 O. Klimov，《近端策略优化算法》，*arXiv*预印本 *arXiv:1707 06347*，2017年。