arXiv:2603.01898v1 [cs.RO] 2 Mar 2026

SaferPath：结合学习型引导与安全约束控制的分层视觉导航

Lingjie Zhang、Zeyu Jiang、Changhao Chen*

摘要——视觉导航是移动机器人的核心能力，但端到端学习方法在未见过的、杂乱或狭窄的环境中往往难以实现良好的泛化和安全性。这些局限在密集室内环境中尤为明显，因为此类环境中很容易发生碰撞，端到端模型也常常失效。为此，我们提出 SaferPath，这是一种分层视觉导航框架，利用现有端到端模型提供的学习型引导，并通过安全约束优化控制模块对其进行优化。SaferPath 将视觉观测转换为可通行区域地图，并使用模型预测 Stein 变分进化策略（MP-SVES）优化引导轨迹，仅需少量迭代即可高效生成安全轨迹。随后，MPC 控制器跟踪优化后的轨迹，确保机器人在复杂环境中实现鲁棒导航。在包含未见障碍物、密集非结构化空间和狭窄走廊的场景中开展的大量实验表明，SaferPath 始终能够提高成功率、减少碰撞，性能优于 ViNT 和 NoMaD 等代表性基线方法，并能在具有挑战性的真实世界环境中实现安全导航。

I. 引言

导航是移动机器人的一项基本能力，使其能够在动态且不确定的环境中自主运行并执行复杂任务。由于先验知识有限，且现实世界本质上难以预测，如何提升机器人在未曾见过的环境中的导航能力，仍是机器人学领域的核心挑战之一 [1]，[2]。传统导航方法通常依赖预先构建的地图（例如占据栅格 [3]或拓扑图[4]）进行路径规划。这些方法往往需要复杂的传感器融合，例如整合激光雷达或深度相机的数据，并采用 A* [5] 或 RRT [6]等规划算法。

随着具身人工智能的快速发展，端到端视觉导航日益受到关注。这些方法利用深度神经网络（DNNs）将视觉输入直接映射为动作，从而减少对显式环境建模和规划的依赖 [1]。然而，其性能高度依赖于大规模、多样化的训练
用于实现稳健泛化的数据集。收集和标注此类数据集成本高昂，而训练环境与部署环境之间的分布不匹配可能导致性能显著下降。此外，真实场景

Lingjie Zhang、Zeyu Jiang 和 Changhao Chen 就职于香港科技大学（广州）PEAK 实验室，地址：中国广州，邮编 511453（zljjacob@gmail.com,zjiang122@connect.hkust-gz.edu.cn,changhaochen@hkust-gz.edu.cn）。本研究得到国家自然科学基金委员会（NFSC）项目（编号：62573370）和广东省教育厅重点领域项目（编号：2025ZDZX3051）的资助。

* 通讯作者。

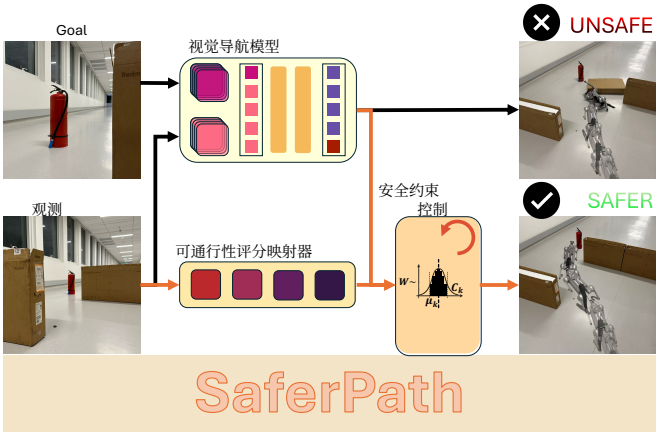


图 1： SaferPath 是一种分层导航框架，采用端到端视觉导航模型提供引导，并集成安全约束控制模块，从而显著提升了在复杂环境中进行安全导航时的避障能力和狭窄通道通行能力。

通常包含未见障碍物、非结构化布局和狭窄通道——例如家用机器人的室内导航场景——这些情况下很容易发生碰撞，安全性至关重要。正如我们的实验所证实的，基于扩散的导航模型 [7] 在这些环境中尤其容易出现性能下降。

这引出了两个基本问题：

Q1. 在多样化的动态环境中部署端到端视觉导航模型时，如何在不重新训练的情况下提升其安全性和鲁棒性？

Q2. 由于训练数据通常缺少密集且狭窄的场景，所提出的方法能否提升模型在此类具有挑战性的环境中的导航性能和安全性？

为应对这些挑战，我们提出了 SaferPath——一种结合学习型引导与安全约束控制的新型分层视觉导航框架。SaferPath 被设计为端到端导航模型之上的灵活模块化层。我们不直接执行端到端模型预测的轨迹，而仅将其用作引导轨迹。具体而言，首先将视觉观测转换为可通行区域地图。随后，将学习得到的引导轨迹通过将问题构建为模型预测优化任务进行优化。为降低非线性优化的高计算需求，我们引入了模型预测 Stein 变分进化策略（MP-SVES），将轨迹优化重新表述为一种高效的变分推断过程。MP-SVES 仅需数次迭代即可生成安全约束解，从而避免了

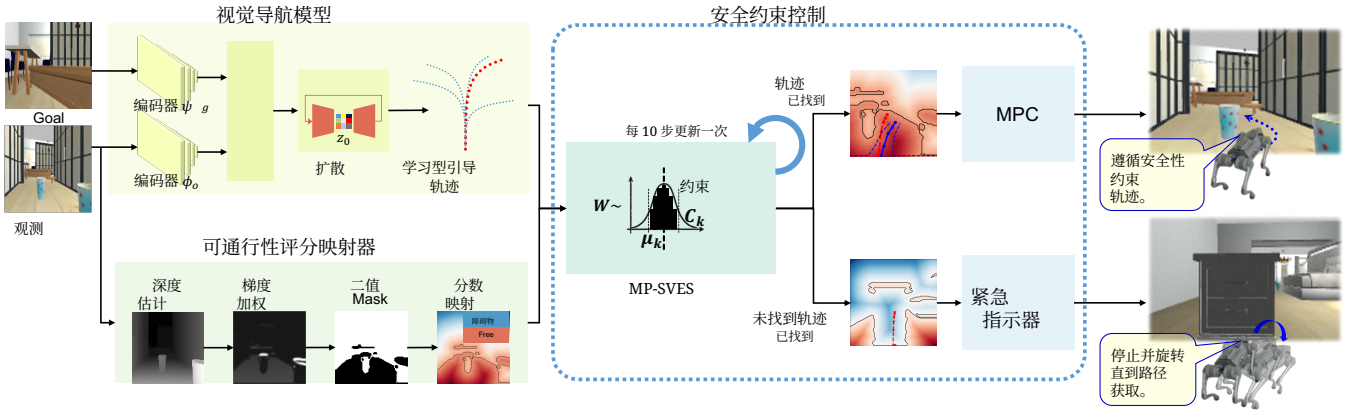


图 2： SaferPath 流水线概览。SaferPath 可与各种端到端视觉导航模型集成。可通行性评分映射器处理 RGB 观测，生成评分图 $\mathcal{S}$，并将其与学习得到的引导轨迹一同传递给 MP-SVES模块。如果优化失败，紧急指示器会让机器人停下并旋转，直到找到可通行轨迹；否则，MPC 控制器将执行轨迹跟踪。

传统非线性求解器高昂的计算成本。随后，由 MPC 控制器跟踪优化后的安全约束轨迹，从而确保在复杂环境中的稳健且精确的导航。

在各种场景中，SaferPath 始终优于强大的基线方法，即使在杂乱或狭窄的环境中，也能保持较高的成功率和较低的碰撞次数。与具有代表性的视觉导航模型 NoMaD [7], 相比，SaferPath 在未知障碍物下的鲁棒导航方面将性能提升了 40%，在密集非结构化环境中的探索方面提升了 50% 以上；此外，在所有基线方法均无法通过的狭窄走廊中，它也能成功导航。

总而言之，我们的主要贡献如下。

- 我们提出了 SaferPath，这是一种分层视觉导航框架，可灵活地构建于端到端模型之上，利用学习型引导并融入安全约束控制，从而提升机器人在复杂未知环境中的导航精度和鲁棒性。
- 我们提出模型预测 Stein 变分进化策略（MP-SVES），这是一种新颖的优化算法，能够高效求解非凸非线性问题，并仅通过少量迭代生成可行且满足安全约束的轨迹。
- 我们在多种场景中开展了广泛实验，包括在存在未见障碍物的情况下进行导航、在密集且无结构的环境中探索，以及在狭窄的室内通道中避障。实验结果表明，SaferPath 的表现显著优于 ViNT 和 NoMaD 等具有代表性的基线方法。

II. 相关工作

A. 具身导航

随着具身智能的发展，与基于几何的方法不同，基于学习的方法侧重于通过从数据驱动的导航经验中学习，开发可靠的导航策略[8]。

通常，基于学习的导航策略被表述为序列预测任务，在生成式建模范式下利用当前和历史观测来生成未来行为[9], [10], [11]。一些研究探索了端到端导航框架，整合了多种异构感知模态，包括激光雷达、深度感知和本体感知测量，以提升长距离全局导航性能 [12], [13],[14]。ViNT[15]及其他近期研究[7], [16], [17]提出了纯视觉、端到端、无地图机器人导航方法，模型直接处理视觉观测序列，以推断未来运动或导航动作，从而能够在复杂或此前未见的环境中实现自主导航。

B. 学习增强的模型预测控制

模型预测控制（MPC）利用已知系统动力学优化控制输入，以预测并调节未来状态。其在实时优化和约束处理方面的优势，使其非常适合具身智能机器人[18]的运动规划。然而，随着计算复杂度的增加以及模型误差随时间累积，MPC 在长时域预测方面的效果较差。

近期研究将基于模型的控制方法与生成模型相结合，利用这些模型的灵活性以及模型预测控制的实时性能和鲁棒性，提升机器人系统中的控制精度和效率。Huang 等人提出了 Subgoal Diffuser，这是一种基于扩散的框架，可生成由粗到细的自适应子目标来引导模型预测控制，从而实现面向长时域机器人操作任务的鲁棒规划[19]。在 SICNav-Diffusion 中，扩散模型与模型预测控制框架相结合，以促进在人群导航环境中的安全轨迹预测[20]。其他研究者[21] 也尝试将模型预测控制与生成模型相结合。在本研究中，我们将端到端视觉导航模型与基于模型预测控制的安全约束下预测相结合，弥补纯端到端方法的局限性，并实现更

可靠且鲁棒的真实世界环境导航。

III. 方法

以往的端到端导航模型通常通过复杂的设计或更大的数据集来提升性能，但在未见环境中的泛化能力仍然较差。为此，我们提出一种分层导航框架：端到端视觉导航模型根据当前和过去的观测提供学习得到的引导轨迹，同时由独立的优化与控制模块确保安全性并施加动态约束。这种设计降低了对端到端模型的依赖，只要求它提供粗略的方向引导，从而实现更可靠的导航。图2展示了整体分层导航框架，后续章节将进一步介绍具体细节。

A. 预备知识

SaferPath 基于端到端视觉导航模型构建。这些模型以机器人的当前及历史 RGB 观测作为输入，并可选择以目标图像或目标位置作为条件。输入首先由视觉编码器处理，生成潜在表示，再传递至下游神经网络以预测轨迹。形式化地，该模型可表示为：

$$f_\theta : \mathbb{R}^{L\times H\times W\times C} \times \mathcal{G} \to \mathbf{X}_t, \quad \mathbf{X}_t = f_\theta(\mathbf{I}_t, g), \quad (1)$$

其中 $\mathbf{I}_t = \{I_{t-L+1}, \ldots, I_t\}$，$\mathbf{I}_t \in \mathbb{R}^{L\times H\times W\times C}$ 表示当前和历史观测，其中 L 为历史长度，H 和 W 分别表示图像高度和宽度，C 为通道数。$g \in \mathcal{G}$ 为目标图像，通常是沿导航路径组织成拓扑地图的一系列图像中的一张。$\mathbf{X}_t = \{\mathbf{x}_0, \ldots\ldots, \mathbf{x}_{t+T}\}$ 表示预测轨迹，其中 $\mathbf{X}_t \in \mathbb{R}^d$ 表示机器人随时间变化的位置轨迹。

例如，我们使用 NoMaD [7]作为基础端到端模型。NoMaD 采用 EfficientNet-B0 编码器 [22]对观测序列 $\mathbf{I}_t$ 和目标图像 g 进行编码，生成标记化的潜在表示 z_t。随后，这些标记由 Transformer层 [23] 处理，以生成上下文向量 c_t，扩散模型[24] 利用该向量预测轨迹 $\mathbf{X}_t$。此外，NoMaD 支持目标掩码输入，从而无需明确目标即可进行探索。

B. 可通行性评分映射器

可通行性评分映射器 (TSM) 模块根据 RGB 图像构建具有安全意识的评分图，以标示用于轨迹规划的可导航区域。首先，使用 DepthAnythingV2 模型进行深度估计 [25]，生成范围为 $[0, 1]$ 的归一化深度图。随后通过高斯平滑减少噪声，并使用 Sobel算子计算垂直梯度，以突出与障碍物相关的深度不连续处。为强调机器人附近的区域，应用一种从图像顶部到底部逐渐增大的空间变化权重。对加权梯度进行阈值处理，生成初步二值地图，将障碍物标记为 0，将可通行区域

算法 1： 通过 MP-SVES 进行轨迹优化

输入： 学习得到的引导轨迹 $\mathbf{X}_{\text{ref},\ t}$、评分图 $\mathcal{S}$

输出： 安全约束轨迹 $\mathbf{X}_{\text{opt},\ t}$

参数： 粒子数 P、样本数 m、迭代次数 N，核权重 γ，步长 η

初始化 $\boldsymbol{\mu}_p, \mathbf{C}_p$ 对于 $p = 1, \ldots, P$

对于 每个时间步 t **执行**

  对于 $n = 1$ **到** N **执行**

    对于 $p = 1$ **到** P **执行**

      $\boldsymbol{\epsilon}_{p,\ i} \sim \mathcal{N}(\mathbf{0},\ \mathbf{I})$，对于 $i = 1, \ldots, m$

      $\mathbf{W}_{p,\ i} \leftarrow \boldsymbol{\mu}_p + \mathbf{L_p}\boldsymbol{\epsilon}_{p,\ i},\ \mathbf{C}_p = \mathbf{L_p}\mathbf{L_p}^\top$

      $J_{p,\ i} \leftarrow J(\mathbf{W}_{p,i}, \mathcal{S}, \mathbf{X}_{\text{ref}})$

      $\omega_{p,i} \leftarrow \frac{\exp(-J_{p,i})}{\sum_{m}^{i=1}\exp(-J_{p,j})}$

      $\Delta\bar{\mathbf{W}}_p \leftarrow \sum_{i=1}^{m} \omega_{p,i}(\mathbf{W}_{p,i} - \boldsymbol{\mu}_p)$

      $\mathbf{g}_p^{\text{ker}} \leftarrow \sum_{q=1,\ q\neq p}^{P-1} \nabla_{\boldsymbol{\mu_p}} \text{ker}(\boldsymbol{\mu}_p,\ \boldsymbol{\mu}_q)$

      $\boldsymbol{\mu}_p \leftarrow \boldsymbol{\mu}_p + \eta \cdot (\Delta\bar{\mathbf{W}}_p + \gamma\mathbf{g}_p^{\text{ker}})$

      $\mathbf{C}_p \leftarrow \mathbf{C}_p + \eta \cdot \sum_{i=1}^{m} \omega_{p,\ i}\boldsymbol{\epsilon}_{p,\ i}\boldsymbol{\epsilon}_{p,i}^\top$

    end

  end

  $\mathbf{W}_t^* \leftarrow$ 参数的最小值 $\mathbf{W}_{p,i}$ $J_{p,i}$ 满足约束

  $\mathbf{X}_{\text{opt},\ t} \leftarrow \mathbf{W}_t^* \cdot \mathbf{X}_{\text{ref},\ t}$

终点

标记为 1，并对底部几行进行调整，以避免误分类。

此二值地图通过水平和垂直梯度分析进行细化，以检测边界并划分障碍物区域与自由空间区域。随后，使用欧几里得距离变换计算到这些区域的逐像素距离，从而生成平滑的评分图。在该地图中，代价定义如下：在障碍物附近为正（离边界越远，数值越大），在自由空间中为负（离边界越远，数值越小），在边界过渡处为零。最后，将该地图归一化至 $[-1, 1]$，生成连续评分图 $\mathcal{S}$，其中封装了用于轨迹规划的安全导航区域。

C. 安全约束控制

我们将来自 TSM 的评分图 $\mathcal{S}$ 用作轨迹规划的安全约束。由于 $\mathcal{S}$ 具有非凸、非线性且高度易变的特性，使用序列二次规划（SQP）[26]或内点法（IPM）[27]等经典方法直接求解最优控制问题，计算开销很大，不适合实时运行。为解决这一问题，我们提出了**模**型**预**测**斯**坦**变**分**进**化**策**略（MP-SVES），将轨迹优化重新表述为模型预测任务。MP-SVES 将基于采样的方法[28]，[29]与斯坦变分策略 [30]，[31] 相结合，以加快收敛速度。随后，使用模型预测控制模块执行安全约束轨迹。

MP-SVES优化： 第一步，将从起点到终点的视觉导航模型得到的引导轨迹 $\mathbf{X}_{\text{ref}} = \left\{ \begin{bmatrix} x^{(k)}_{\text{ref}} & y^{(k)}_{\text{ref}} \end{bmatrix} \right\}_{k=0}$

传递给 MP-SVES 优化模块。该模块的目标是在调整学习得到的引导轨迹参数的同时对其进行优化，确保安全约束轨迹尽可能接近学习得到的引导轨迹，并满足评分图 $\mathcal{S}$ 所定义的安全约束。优化通过对学习得到的引导轨迹点进行各向异性缩放来实现：

$$\mathbf{X}_{\text{opt}}^{(k)} = \begin{bmatrix} x_{\text{opt}}^{(k)} \\ y_{\text{opt}}^{(k)} \end{bmatrix} = \begin{bmatrix} w_x & 0 \\ 0 & w_y \end{bmatrix} \begin{bmatrix} x_{\text{ref}}^{(k)} \\ y_{\text{ref}}^{(k)} \end{bmatrix}, \quad k = 0, \ldots, K-1, \tag{2}$$

其中， w_x 和 w_y 是优化参数，用于控制学习得到的引导轨迹在 x 和 y 维度上的缩放。这种基于缩放的方法既能保留原始轨迹的关键几何特征（如整体形状和航向），又能灵活调整轨迹大小，从而更好地满足安全约束。

MP-SVES优化算法将轨迹优化表述为一个模型预测问题，其目标是在满足系统动力学和可行性约束的条件下，确定使以下目标函数最小化的最优缩放参数$\mathbf{W} = \text{diag}(w_x, w_y)$:

$$\begin{aligned} \min_{\mathbf{W}} J(\mathbf{W}, \mathcal{S}, \mathbf{X}_{\text{ref}}) = & \sum_{k=0}^{K-1} \|\mathbf{X}_{\text{opt}}^{(k)} - \mathbf{X}_{\text{ref}}^{(k)}\|_Q^2 \\ & + \lambda_s \sum_{k=0}^{K-1} \mathcal{S}\left(\mathcal{X}_{\text{tube}}^{(k)}\right) + \lambda_r \|\mathbf{W} - \mathbf{I}\|_2^2 \\ \text{s. t.} \quad & \mathbf{X}_{\text{opt, init}} = \mathbf{X}_{\text{ref}} \\ & \mathbf{X}_{\text{opt}}^{(k)} = \mathbf{W} \cdot \mathbf{X}_{\text{ref}}^{(k)}, \quad k = 0, \ldots, K-1 \\ & \mathcal{S}\left(\mathcal{X}_{\text{tube}}^{(k)}\right) \le \delta, \quad k = 0, \ldots, K-1 \\ \text{where} \quad & \mathcal{X}_{\text{tube}}^{(k)} = \left\{ \mathbf{X}_{\text{opt}}^{(k)} + \alpha\, \mathbf{n}^{(k)} \;\middle|\; \alpha \in [\frac{-d}{2}, \frac{d}{2}] \right\}, \end{aligned} \tag{3}$$

K 是每个时间步的预测时域。 Q、 λ_s和 λ_r是调节参数，分别用于控制跟踪精度、安全性和正则化。 d 表示机器人的宽度。$n^{(k)}$ 表示在时间步 k处与轨迹正交的单位法向量。

该公式旨在求得一组缩放参数，使安全约束轨迹在满足安全约束的同时接近学习得到的引导轨迹。用于更新$\mathbf{W}$ 并获得安全约束轨迹的MP-SVES迭代过程总结于算法1中，其中$\boldsymbol{\mu_p}$ 和$\mathbf{C_P}$ 分别表示粒子 p的均值和协方差矩阵。排斥梯度 $\nabla_{\mu_p}\text{ker}(\boldsymbol{\mu}_p, \boldsymbol{\mu}_q)$是核函数的梯度，通常采用RBF核$\text{ker}(\boldsymbol{\mu}_p, \boldsymbol{\mu}_q) = \exp\left(-\frac{\|\boldsymbol{\mu}_p - \boldsymbol{\mu}_q\|^2}{2\sigma^2}\right)$，以产生排斥力，防止模式坍塌并保持多样性。$\mathbf{W}_t^*$表示满足安全约束的最优缩放参数。

在实际应用中，MP-SVES算法仅需约10次迭代即可获得一条可行的安全约束轨迹，
使其比直接在评分图上进行优化的梯度下降方法显著更高效。
当

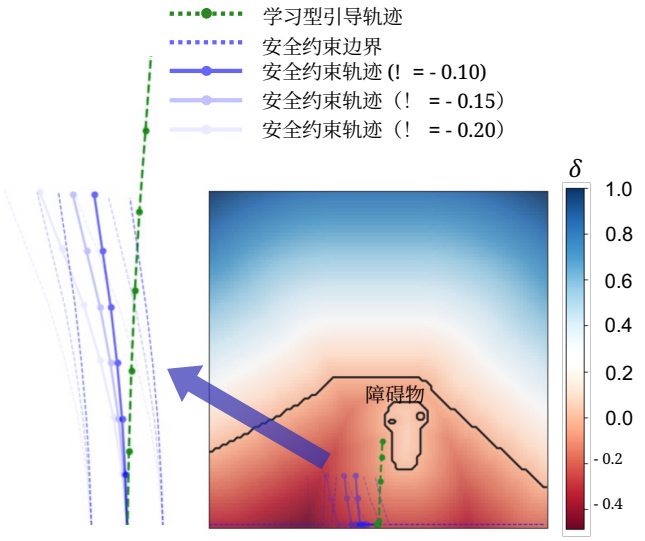


图 3: 不同安全阈值下的安全约束轨迹。机器人通过调整阈值 δ，与障碍物保持不同的安全距离

遇到障碍物时，我们改变安全阈值，以展示安全约束轨迹如何变化：阈值越小（越负），安全约束越严格，导致安全约束轨迹偏离障碍物更远（图 3）。如果障碍物距离过近，无法找到可行解，则将这种情况判定为危险。在此情况下，EmergencyIndicator 会命令机器人立即停止，并转向自由空间区域较大的一侧，直到获得可行的安全约束轨迹。

模型预测控制：获得安全约束轨迹后，将其传递给模型预测控制模块。该模块用于在每个时间步 t 计算最优控制输入 $\mathbf{U}_t = (v_t, \omega_t)$，确保机器人状态 $\mathbf{X}_t = (x_t, y_t, \theta_t)$ 紧密跟踪安全约束轨迹 $\mathbf{X}_{\text{opt}}$，同时满足系统动力学和物理约束。模型预测控制问题表述如下：

$$\begin{aligned} \min_{\mathbf{U}_t^{(0)}, \ldots, \mathbf{U}_t^{(K-1)}} & \left\{ \sum_{k=0}^{K-1} \left(\|\mathbf{X}_t^{(k)} - \mathbf{X}_{\text{opt},t}^{(k)}\|_Q^2 + \|\mathbf{U}_t^{(k)}\|_R^2 \right) \right. \\ & \left. + \underbrace{\|\mathbf{X}_t^{(K)} - \mathbf{X}_{\text{opt},t}^{(K)}\|_{Q_f}^2}_{\text{terminal cost}} \right\} \\ \text{s.t.} \quad & \mathbf{X}_t^{(0)} = \mathbf{X}_{\text{opt},t}^{(0)}, \\ & \mathbf{X}_t^{(k+1)} = f(\mathbf{X}_t^{(k)}, \mathbf{U}_t^{(k)}), \quad k = 0, \ldots, K-1, \\ & \mathbf{X}_t^{(k)} \in \mathcal{X}, \; \mathbf{U}_t^{(k)} \in \mathcal{U}, \quad k = 0, \ldots, K-1, \end{aligned} \tag{4}$$

其中， $f(\cdot)$ 表示机器人的运动学模型， $\mathbf{U}_t^{(k)} = (v_t^{(k)}, \omega_t^{(k)})$ 是时间 $t+k$ 的控制输入， $\mathcal{X}$ 和 $\mathcal{U}$ 分别是可行状态约束集和控制输入约束集。

模型预测控制的目标函数是惩罚偏离安全约束轨迹 $\mathbf{X}_{\text{opt}}$ 的情况以及过大的控制输入，同时确保轨迹始终处于

动态约束范围内。

机器人的运动学模型 $f(\cdot)$ 定义如下：

$$\begin{aligned} x_{t+1} &= x_t + v_t \cos(\theta_t)\Delta t, \\ y_{t+1} &= y_t + v_t \sin(\theta_t)\Delta t, \\ \theta_{t+1} &= \theta_t + \omega_t \Delta t, \end{aligned} \tag{5}$$

其中 Δt为时间步。

完整流程 整个流程总结如下：

- **MP-SVES优化** 对学习得到的引导轨迹进行优化，确保其满足安全约束，同时尽可能贴近学习得到的引导轨迹。
- **MPC控制**基于安全约束轨迹计算最优控制输入，确保机器人遵循该轨迹，同时满足动态和物理约束。

通过结合MP-SVES优化与MPC控制，该方法能够在动态狭窄环境中实现鲁棒的轨迹跟踪。

IV. 实验

本节通过全面的实验评估我们方法的有效性。IV-A节介绍实验设置。IV-B节评估面对先前未见障碍物时的鲁棒性。IV-C节评估在密集环境中进行无引导探索时的避障性能。IV-D节测试狭窄走廊中的导航，这要求精确避障和路径规划。IV-E节在真实场景中验证我们的方法，展示其在实际条件下安全、可靠的导航能力。最后，IV-F节通过消融研究分析各个模块的作用。

A. 实验设置

基线方法： 我们将本方法与以下纯RGB视觉导航基线方法进行比较：

- **通用导航模型（GNM）：** 一种通用视觉导航策略，在多个环境和机器人平台上采集的多样化数据集上训练而成 [16]。
- **视觉导航Transformer（ViNT）：** 一种用于视觉导航的基于Transformer的基础模型，通过基于扩散模型的规划生成子目标 [15]。
- **基于目标掩蔽扩散的导航（NoMaD）：** 一种基于扩散模型的导航策略，可在未知环境中处理目标导向导航与探索 [7]。

数据集： 为确保公平比较，所有方法均使用同一组导航数据集进行训练：

- **SACSoN/HuRoN：** 70+ 小时的人机交互室内轨迹[32]。
- **SCAND：** 来自 Spot 和 Jackal 机器人的 9 小时轨迹，涵盖多种社交导航场景 [33]。

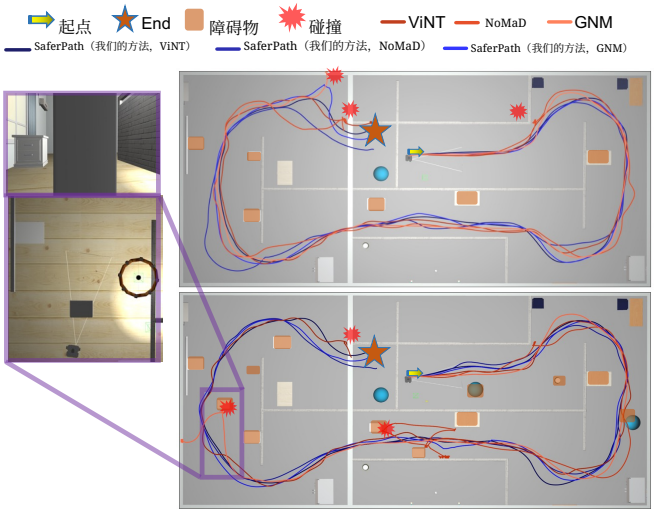


图 4： 该图展示了在未知障碍物下的鲁棒导航实验中的场景。上方场景（场景 A）在原始环境的道路两侧设置障碍物；下方场景（场景 B）则包含场景 A 中的所有障碍物，并在道路中间增设了障碍物。图中展示了我们的方法取得成功的轨迹示例，以及基线方法发生碰撞的情形示例。

- **GoStanford2：** 在多个校园建筑中收集的 Turtlebot2 轨迹，共计 16 小时 [34]。
- **RECON：** 18 个月的导航数据，支持在多种环境中开展跨领域任务 [35]。

训练： 所有方法均使用上述数据集中的 RGB 图像和轨迹序列进行训练，使用单张 NVIDIA RTX 4090 GPU，批量大小为 256，训练 20 轮。

评估指标： 我们使用成功率 和每次试验的平均碰撞次数来评估导航性能。所有仿真实验和消融研究均重复进行 50 次，以确保统计可靠性。

场景配置： 所有评估场景在训练期间均未出现。我们在固定时间范围内记录机器人的完整轨迹。如果机器人在此时间限制内到达指定目标区域，则该次试验视为成功；否则，记为失败。在到达目标之前，每当机器人短暂接触障碍物或墙壁时，均计为一次碰撞。

B. 未见障碍物下的鲁棒导航 *les*

在本实验中，我们评估机器人遇到学习型引导中未包含的障碍物时，框架的鲁棒性。具体而言，我们使用在不含这些障碍物的原始环境中生成的引导，并在部署期间沿导航路径加入额外的、此前未见过的障碍物，同时保持引导不变。这一设置包含动态环境变化，可用于测试模型应对意外扰动的能力。

实验设计如图 4 所示：障碍物被随机放置在室内走廊中，以干扰规划的导航轨迹。在场景 A 中，障碍物被放置在走廊两侧，

表 I： 未知障碍物下的鲁棒导航实验性能比较。在相同场景中，我们的方法优于所有基线方法。向场景中引入更多障碍物时，与基线方法相比，我们的方法性能下降更少。

方法	场景 A		场景 B	
	成功率（%）	碰撞	成功率 (%)	碰撞
GNM	68	0.70	26	1.22
ViNT	94	0.22	80	0.80
NoMaD	56	1.46	20	2.34
SaferPath(我们的, GNM)	82	0.08	74	**0.06**
SaferPath(我们的, ViNT)	94	**0**	**94**	0.08
SaferPath(我们的, NoMaD)	**98**	0.02	**94**	**0.06**

表 II： 密集非结构化环境中的探索实验性能比较。与基线方法相比，我们的方法展现出显著更强的避障能力。

方法	成功率（%）	碰撞
NoMaD	38	2.66
SaferPath（我们的方法，NoMaD）	**96**	**0.04**

对机器人的视野造成的遮挡较少。在场景 B 中，更多障碍物被放置在走廊中间，造成严重遮挡，使导航面临更大的挑战。如图 4 所示，这些遮挡可能会暂时限制机器人的视场，导致引导信息部分或完全丢失，并可能产生不安全的轨迹预测。

表 I 总结了实验结果。SaferPath（Ours, GNM/ViNT/NoMaD）表示我们基于这些端到端视觉导航模型构建的框架。在场景 A 中，仅增加少量障碍物时，所有基线方法均取得了中等水平的成功率。在遮挡更严重的场景 B 中，基线方法的性能显著下降：GNM 和 NoMaD 的下降幅度更大，而 ViNT 的鲁棒性相对较强。NoMaD 的碰撞次数也较高，这可能是因为它在训练期间依赖目标掩码；当无法获得引导时，这可能导致不安全轨迹。相比之下，在这种情况下，GNM 和 ViNT 的行为更加保守。集成我们的模块后，所有增强版本在场景 A 和场景 B 中都保持了较高的成功率和较低的碰撞次数，即使在严重遮挡下，性能也仅略有下降。这些结果表明，我们的模块能够有效缓解引导不可用的问题，从而在动态变化环境中实现安全可靠的导航。

C. 密集非结构化环境中的探索

在此实验中，我们评估该框架在没有明确目标引导的情况下，探索具有密集障碍物的复杂非结构化环境的能力。

该方法利用目标掩码机制，无需外部输入即可进行探索。我们构建了一个密集障碍物场，并将机器人初始化在该区域内（见图 5）。若机器人在预设时间限制内离开障碍物场，则视为任务成功。我们使用两个指标评估性能：成功率和平均碰撞次数。

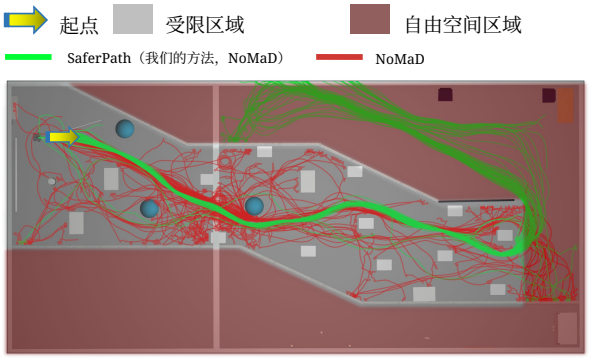


图5： 在密集非结构化环境中的探索实验中，SaferPath（我们的方法、NoMaD）的轨迹（绿色）有效避开了密集障碍物，并到达自由空间区域。相比之下，NoMaD 的轨迹（红色）更加混乱，导致碰撞显著增多。

表III： 狭窄走廊避障实验中的性能比较。我们的方法显著优于基线方法，而所有基线方法在本实验中均告失败。

方法	成功率（%）	碰撞
GNM	0	4.36
NoMaD	0	4.10
ViNT	0	4.04
SaferPath（我们的方法，GNM）	76	0.42
SaferPath（我们的方法，NoMaD）	54	0.52
SaferPath（我们的方法，ViNT）	**80**	**0.16**

表 II 展示了结果。在没有引导的密集障碍物场中，我们的方法能够有效避开障碍物，并实现可靠导航。与 NoMaD 相比，该方法的成功率提高了 50% 以上，同时显著减少了碰撞次数，体现了其在无引导探索场景中的鲁棒性和安全性。

D. 狭窄走廊避障

在本实验中，我们评估了方法在狭窄且无结构的室内环境中的导航性能（见图 7）。这种场景对准确避障以及在狭窄走廊中进行精确路径规划提出了严格要求，因为即使是微小的偏差也可能导致撞墙。通道的不规则布局进一步考验了不同方法的实时性能和鲁棒性。

表III总结了实验结果。所有基线方法在这项要求严苛的导航任务中均告失败，无法在如此狭窄的空间中保持安全轨迹。相比之下，配备我们模块的三个增强版本取得了显著更高的成功率和更少的碰撞次数。以 ViNT 为例，我们将原始版本和增强版本在所有试验中的轨迹进行了可视化。结果清楚地表明，我们的模块使机器人能够始终行驶在安全通道区域内，而原始 ViNT 则频繁产生不安全轨迹，导致碰撞和任务失败。

E. 四足机器人真实世界导航

我们开展了真实世界实验，以验证我们的方法在实际场景中的有效性。实验

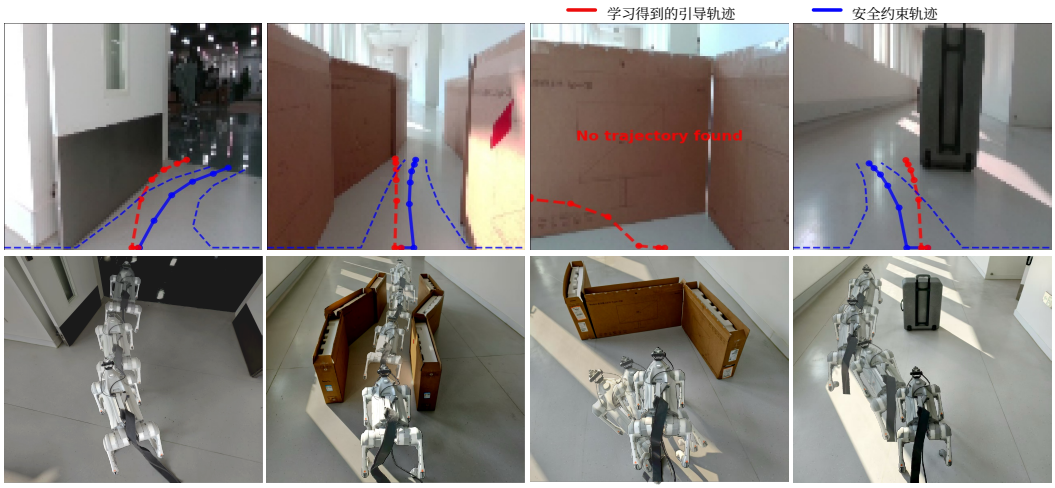


图 6： 我们将 SaferPath 部署在宇树 Go2 上，它成功避开了未见过的障碍物和动态障碍物，穿过狭窄空间，并始终保持在安全区域内。当没有可通行轨迹时，紧急指示器会让机器人停下，并将其重新定向至安全方向。

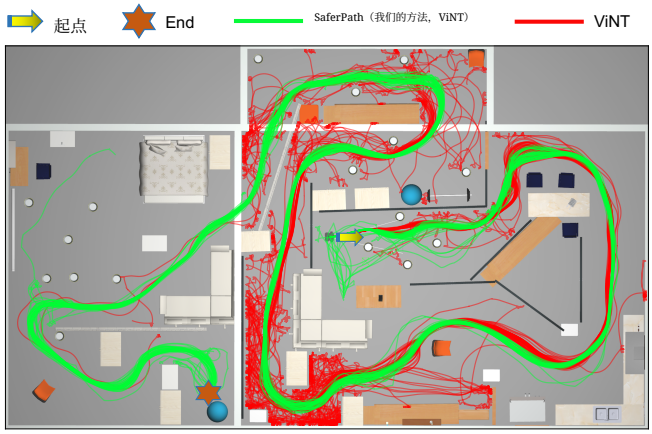


图 7： 该图展示了狭窄走廊避障实验中的部分轨迹。与 ViNT（红色）相比，SaferPath（我们的方法，ViNT）的轨迹（绿色）明显更加平滑、安全，碰撞也显著更少。这表明，在复杂环境中，SaferPath 的避障能力和鲁棒性优于 ViNT。

在一台配备英特尔 D435i 摄像头的宇树 Go2 四足机器人上进行，感知时仅使用其 RGB 功能。在导航任务中，我们部署了 SaferPath（我们的方法）和 NoMaD 进行比较。图 6 展示了若干具有代表性的场景，其中四种基线方法容易发生碰撞。在这些情况下，参考轨迹常使机器人危险地接近障碍物。相比之下，集成 SaferPath 后，机器人能够：(i) 与侧墙保持安全距离；(ii) 无碰撞地通过狭窄通道；(iii) 在紧急情况下迅速停车并重新规划可行路径；(iv) 避开位于其轨迹中央的障碍物。这些结果表明，SaferPath 能够在真实世界环境中实现稳健、安全的导航，并有效应对狭窄通道和动态障碍物。

表 IV： 消融研究表明，所有模块都不可或缺，其中 MP-SVES 对系统稳定性和性能最为关键。

方法	成功率（%）	碰撞
SaferPath（我们的方法，不含 TSM、ViNT）	60	1.34
SaferPath（我们的方法，不含 MP-SVES、ViNT）	0	2.28
SaferPath（本文方法，不含Em，ViNT）	70	1.14
SaferPath（本文方法，ViNT）	**80**	**0.16**

F. 消融研究

为分析各组件的贡献，我们通过选择性地移除可通行性评分映射器（TSM）、MP-SVES和紧急指示器模块进行消融研究：

- 不含*TSM*：移除可通行性评分映射器，从而消除评分图安全约束。
- 不含*MP-SVES*：移除MP-SVES模块，将所有约束放入MPC模块，并使用传统非线性求解器IPOPT[36]进行求解。
- 不含 *Em*：移除紧急指示器模块，因此当安全约束轨迹不可行时，直接执行学习得到的引导轨迹。

我们使用 ViNT 作为底层端到端视觉导航模型，重复了复杂环境中的避障实验。表 IV 总结了实验结果。移除任何模块都会导致性能下降。特别是，移除 MP-SVES 会使成功率降至 0%，凸显了该模块在确保系统稳定性方面的关键作用。移除可通行性评分映射器后，成功率下降 20%，碰撞次数显著增加，凸显了其对避障的重要性。移除紧急指示器模块也会降低成功率并增加碰撞次数，表明该模块在极端情况下不可或缺。

这些结果直接回应了引言中提出的研究问题。对于 **Q1**，所提出的模块显著提升了端到端视觉导航的安全性和鲁棒性：在存在额外障碍物的环境中，增强后的模型仍能保持较高的成功率和较低的碰撞次数，

这表明可行且安全的轨迹得以保留。对于 **Q2**，在训练数据中代表性不足的狭窄且杂乱的环境中，该模块能够实现高效且无碰撞的导航，带来显著的性能提升。在仿真和真实世界实验中取得的一致结果，证实了我们方法的有效性和普适性。

V. 结论

我们提出了 SaferPath，这是一种分层视觉导航框架，利用端到端视觉导航模型提供的学习型引导，同时确保轨迹执行安全且可行。SaferPath 有效利用这些模型提供的方向信息，并采用 MP-SVES算法优化轨迹，仅需数次迭代即可生成安全约束路径，同时兼顾安全区域导航和紧急避障。大量实验表明，我们的方法比当前最先进的端到端视觉模型性能高出 40% 以上，即使在复杂狭窄的环境中也能实现安全导航。

尽管取得了这些改进，该方法仍受限于 RGB观测视场有限的问题；当障碍物位于摄像头视野之外时，可能会发生碰撞。未来的工作将致力于融入更丰富的感知模态和预测性场景理解，以进一步提升方法在杂乱、动态环境中的鲁棒性。

参考文献

[1] Y. Liu、L. Liu、Y. Zheng、Y. Liu、F. Dang、N. Li 和 K. Ma，《具身导航》，中国科学：信息科学，第 68 卷，第 4 期，页码 141101，2025。[2] T. Zhang、X. Hu、J. Xiao 和 G. Zhang，《视觉导航综述：从几何到具身人工智能》，《人工智能工程应用》，第 114 卷，页码 105036，2022。[3] A. Elfes，《使用占据栅格进行移动机器人感知与导航》，《计算机》，第 22 卷，第 6 期，1989。[4] S. Thrun 和 A. Bücken，《融合基于栅格与拓扑地图的移动机器人导航》，载于全国人工智能大会论文集，1996，第 944–951 页。[5] P. E. Hart、N. J. Nilsson 和 B. Raphael，《最小代价路径启发式确定的形式化基础》，*IEEE*《系统科学与控制论汇刊》，第 4 卷，第 2 期，第 100–107 页，1968。[6] S. M. LaValle，《快速探索随机树：一种新的路径规划工具》，年度研究报告，1998。[7] A. Sridhar、D. Shah、C. Glossop 和 S. Levine，《NoMaD：用于导航与探索的目标掩码扩散策略》，*arXiv* 预印本，2023。[8] H. Liu、D. Guo 和 A. Cangelosi，《具身智能：形态学、动作、感知与学习的协同》，*ACM*计算调查，2025 年 2 月。[9] W. Zheng、R. Song、X. Guo、C. Zhang 和 L. Chen，《Genad：生成式端到端自动驾驶》，*arXiv* 预印本 *arXiv: 2402.11502*，2024。[10] Y. Hu、J. Yang、L. Chen、K. Li、C. Sima、X. Zhu、S. Chai、S. Du、T. Lin、W. Wang、L. Lu、X. Jia、Q. Liu、J. Dai、Y. Qiao 和 H. Li，《规划导向的自动驾驶》，载于*IEEE/CVF*计算机视觉与模式识别会议论文集，2023。[11] G. Kahn、P. Abbeel 和 S. Levine，《Badgr：一种基于自主自监督学习的导航系统》，*IEEE*《机器人与自动化快报》，第 6 卷，第 2 期，第 1312–1319 页，2021。[12] J. Liang、P. Gao、X. Xiao、A. J. Sathyamoorthy、M. Elnoor、M. C. Lin 和 D. Manocha，《Mtg：用于户外导航、具备可通行性覆盖能力的无地图轨迹生成器》，载于*2024 IEEE*国际机器人与自动化会议（*ICRA*）。IEEE，2024，第 2396–2402 页。

[13] J. Liang、A. Payandeh、D. Song、X. Xiao 和 D. Manocha，《Dtg：用于无地图全局导航的基于扩散的轨迹生成》，2024。[14] A. Saviolo 和 G. Loianno，《Nova：在无结构、GPS 拒止环境中通过以物体为中心的视觉自主实现高速目标跟踪导航》，arXiv 预印本 arXiv:2506.18689，2025。[15] D. Shah、A. Sridhar、N. Dashora、K. Stachowicz、K. Black、N. Hirose 和 S. Levine，《ViNT：用于视觉导航的基础模型》，载于第 7 届机器人学习年会，2023。[16] D. Shah、A. Sridhar、A. Bhorkar、N. Hirose 和 S. Levine，《GNM：通用导航模型，驱动任意机器人》，载于国际机器人与自动化会议（ICRA），2023。[17] Y. Zeng、H. Ren、S. Wang、J. Huang 和 H. Cheng，《Navidiffusor：用于视觉导航的代价引导扩散模型》，arXiv 预印本 arXiv:2504.10003，2025。[18] R. Grandia、F. Farshidian、A. Dosovitskiy、R. Ranftl 和 M. Hutter，《频率感知模型预测控制》，IEEE《机器人与自动化快报》，第 4 卷，第 2 期，第 1517–1524 页，2019。[19] Z. Huang、Y. Lin、F. Yang 和 D. Berenson，《Subgoal diffuser：通过由粗到细的子目标生成，引导机器人操作的模型预测控制》，载于2024 IEEE国际机器人与自动化会议（ICRA），2024，第 16 489–16 495 页。[20] S. Samavi、A. Lem、F. Sato、S. Chen、Q. Gu、K. Yano、A. P. Schoellig 和 F. Shkurti，《Sicnav-diffusion：基于扩散轨迹预测的安全交互式人群导航》，IEEE《机器人与自动化快报》，第 10 卷，第 9 期，第 8738–8745 页，2025。[21] H. Xue、C. Pan、Z. Yi、G. Qu 和 G. Shi，《通过扩散式退火实现力矩级运动控制的全阶基于采样的模型预测控制》，2024。[22] M. Tan 和 Q. V. Le，《Efficientnet：重新思考卷积神经网络的模型缩放》，2020。[23] A. Vaswani、N. Shazeer、N. Parmar、J. Uszkoreit、L. Jones、A. N. Gomez、L. Kaiser 和 I. Polosukhin，《注意力就是你所需要的一切》，2023。[24] J. Ho、A. Jain 和 P. Abbeel，《去噪扩散概率模型》，2020。[25] L. Yang、B. Kang、Z. Huang、X. Xu、J. Feng 和 H. Zhao，《Depth Anything：释放大规模无标注数据的力量》，载于 CVPR，2024。[26] J. F. Bonnans、J. C. Gilbert、C. Lemaréchal 和 C. A. Sagastizábal，《数值优化：理论与实践》，1997 年法文版译本的第二次修订版，丛书《Universitext》。柏林：施普林格出版社，2006。[27] S. J. Wright，《原对偶内点法》。工业与应用数学学会，1997。[28] E. Theodorou、J. Buchli 和 S. Schaal，《一种用于强化学习的广义路径积分控制方法》，机器学习研究期刊，第 11 卷，第 104 期，第 3137–3181 页，2010。[29] G. Williams、P. Drews、B. Goldfain、J. M. Rehg 和 E. A. Theodorou，《使用模型预测路径积分控制实现激进驾驶》，载于 2016 IEEE国际机器人与自动化会议（ICRA），2016，第 1433–1440 页。[30] Q. Liu 和 D. Wang，《Stein变分梯度下降：一种通用贝叶斯推断算法》，2019。[31] C. V. Braun、R. T. Lange 和 M. Toussaint，《Stein变分进化策略》，ArXiv，第 abs/2410.10390 卷，2024。[32] N. Hirose、D. Shah、A. Sridhar 和 S. Levine，《Sacson：可扩展的社交导航自主控制》，IEEE《机器人与自动化快报》，第 9 卷，第 1 期，第 49–56 页，2024。[33] H. Karnan、A. Nair、X. Xiao、G. Warnell、S. Pirk、A. Toshev、J. Hart、J. Biswas 和 P. Stone，《社会合规导航数据集（SCAND）：用于社交导航的大规模示范数据集》，IEEE《机器人与自动化快报》，2022。[34] N. Hirose、A. Sadeghian、M. Vázquez、P. Goebel 和 S. Savarese，《Gonet：一种用于可通行性估计的半监督深度学习方法》，第 3044–3051 页，2018。[35] D. Shah、B. Eysenbach、N. Rhinehart 和 S. Levine，《利用潜在目标模型实现开放世界导航的快速探索》，载于第 5 届机器人学习年会，2021。[36] F. E. Curtis、O. Schenk 和 A. Wächter，《一种用于大规模非线性优化的不精确步长计算内点算法》，SIAM科学计算期刊，第 32 卷，3475，2010 6，3447 第 – 页。