

油气田巡检机器人三层协同控制系统研究

胡佑东^{1,2}, 朱豫川¹, 王旭¹

(1. 中国石油西南油气田公司 蜀南气矿, 四川 泸州 646000;

2. 西南石油大学 电气信息学院, 成都 610500)

摘要: 为提升油气田复杂地形环境下巡检机器人的运动稳定性与环境适应性, 增强其越障能力, 该研究对三层协同控制架构及其在油气田巡检机器人系统中的应用进行了深入分析; 其采用 D-H 参数法构建关节坐标系链, 生成位移控制矩阵以实现高精度定位; 结合五次多项式轨迹与模型预测控制滚动优化, 实时抑制横滚与俯仰振动; 融合栅格高程感知模型, 优化落脚点序列以最小化路径坡度, 最终构建感知-控制闭环系统, 显著提升了机器人在陡坡与沟壑地形中的稳定性和自适应能力; 实验测试表明, 该控制系统有效改善了机器人的转向不稳定和轨迹偏移问题, 机身姿态波动范围不超过 0.02 rad, 动态稳定测试中俯仰角摆动接近 0 rad, 爬坡误差率低于 2.5%, 表现出优良的控制性能与环境适应性; 该研究所构建的三层协同控制系统为油气田高危环境下的机器人安全巡检提供了可靠的技术支撑, 显著提升了其在复杂环境中的越障能力。

关键词: 运动学; 机器人; 多项式轨迹; 姿态角; 控制; 环境感知; 自适应

Research on Three-Level Collaborative Control System for Oil and Gas Field Inspection Robots

HU Youdong^{1,2}, ZHU Yuchuan¹, WANG Xu¹

(1. Shunan Gas Mine, Southwest Oil and Gas Field Company, PetroChina, Luzhou 646000, China;

2. College of Electrical and Information Engineering, Southwest Petroleum University, Chengdu 610500, China)

Abstract: To enhance the motion stability and environmental adaptability of inspection robots in complex terrains of oil and gas fields, and to improve their obstacle-crossing performance, this research conducted an in-depth analysis of a three-layer collaborative control architecture and its application in an inspection robot system. The D-H parameter method was employed to construct a joint coordinate system chain and generate a displacement control matrix for high-precision positioning. The integration of fifth-order polynomial trajectories with model predictive control rolling optimization was used to suppress roll and pitch vibrations in real time. A grid elevation perception model was fused to optimize the landing point sequence for minimizing path slope, ultimately forming a perception-control closed-loop system that significantly enhanced the robot's stability and adaptability on steep slopes and gullies. Experimental results demonstrated that the proposed control system effectively improved steering instability and trajectory deviation, with body attitude fluctuation not exceeding 0.02 rad. During dynamic stability tests, the pitch angle swing remained near 0 rad, and the climbing error rate was below 2.5%, indicating excellent control performance and environmental adaptability. The three-layer collaborative control system developed in this study provides reliable technical support for safe robot inspections in high-risk oil and gas field environments and significantly enhances the robot's obstacle-crossing capability in complex terrains.

Keywords: kinematics; robot; polynomial trajectory; attitude angle; control; environmental perception; adaptability

0 引言

复杂地形中的陡坡、沟壑及非结构化路面进一步增加了作业难度, 对机器人的运动控制能力提出了严峻挑战^[1]。现有巡检机器人普遍存在崎岖地形适应性差、运

动失稳风险高、落脚点选择缺乏感知依据等问题, 极大限制了其在复杂油气田场景的部署应用^[2]。针对差动机器人高速运行时路径跟踪能力与速度维持能力的冲突问题, 文献 [3] 提出基于预瞄速度调节与非线性模型预测 (MPC, model predictive control) 的控制系统。其

收稿日期:2025-08-15; 修回日期:2025-09-16。

作者简介:胡佑东(1984-),男,大学本科,工程师。

引用格式:胡佑东,朱豫川,王旭. 油气田巡检机器人三层协同控制系统研究[J]. 计算机测量与控制, 2025, 33(10): 151-157, 243.

通过动态协调纵向速度与转弯曲率关系,能够主动调节速度以保障跟踪精度。文献[4]针对全向移动机器人在未知障碍环境中精确轨迹跟踪的难题,提出基于非线性 MPC 控制的创新方案。其通过基于密度的带噪声应用空间聚类表征障碍物,能够有效实现窄通道穿越与动态避障。针对四足机器人在非结构化地形中深度强化学习控制收敛慢的问题,文献[5]提出融合记忆组件的双延迟深度确定性策略梯度控制算法。其通过优化学习机制提升收敛效率与稳定性,能够显著改善机器人在复杂地形下的运动控制与越障性能。文献[6]针对双足机器人动态平衡中零力矩点跟踪与复杂环境适应性问题,提出基于重心轨迹预测控制的方法。其通过预先调控质心运动路径应对路径突变,能够有效解决连续变动的零力矩点跟踪难题,提升机器人行走稳定性。针对油田巡检机器人路径规划存在的地形适应性不足问题,文献[7]提出一种基于双分辨率分层栅格地图的改进动态加权 A* 算法。其通过构建高低分辨率分层地图并融合路径代价函数,降低了存储负载并提升路径平缓度及规划效率。文献[8]针对气田定位任务中多机器人信息路径规划问题,提出一种基于稀疏高斯过程与梯度下降优化的高效方法。其通过在连续环境中直接优化路径,并同时兼顾多目标路径约束,实现了适用于单机/多机场景的通用信息路径规划。

然而现有方法难以兼顾突变地形姿态稳定与落脚点协同优化,且依赖预训练模型或固定平衡策略,在油气田极端环境下存在明显局限。MPC 方案缺乏地形前馈机制,姿态振荡幅度高达 0.15 rad;强化学习在新地形中位姿误差增加 32.5%;规划算法未与控制层实时协同,路径跟踪延迟超 200 ms。因此,研究聚焦于 MPC 与地形感知的优势协同,提出位姿稳定器及脚点优化器,并最终构建基于三层协同控制系统的油气田巡检机器人系统。研究旨在通过三层协同控制解决突变坡面下姿态稳定性与落脚点安全的动态平衡难题,实现崎岖油气地形的自主巡检。研究创新性在于融合丹纳维特-哈滕贝格(D-H, denavit-hartenberg)参数法运动链位移控制与栅格高程梯度感知,通过三层协同控制系统中的位姿稳定器(中层)与脚点优化器(上层)协同机制,形成从机身动态抑振到坡角自适应步态的级联优化范式。

1 油气田巡检机器人三层协同控制系统

1.1 三层协同控制系统总体架构

针对油气田巡检中复杂地形(如陡坡、沟壑、碎石滩及非结构化路面)对机器人运动控制的严峻挑战,以及高温、高湿、腐蚀性气体和视觉遮挡等复合干扰因素构成的极端作业环境,当前四足巡检机器人在实现自主

巡逻时面临感知-决策-控制链路的实时性与可靠性、突变地形下的动态稳定性以及全局安全与局部性能的统筹等问题。然而,现有方法普遍存在崎岖地形适应性差、运动失稳风险高以及落脚点优化不足等问题,依赖预训练模型或固定策略,难以应对油气田环境中地形突变、振动干扰和感官退化等多重不确定因素。为此,研究提出一种创新的三层协同控制系统,旨在通过层间级联优化解决突变地形下的姿态稳定与落脚点安全协同难题,提升机器人在高危环境中的自主巡检性能与越障能力。研究的三层协同控制系统总体架构设计,基于“分级递阶控制”与“时间尺度分离”原则进行推导与构建。其核心设计依据如下:首先,依据控制系统的频响特性,将响应最快的底层关节位移控制、中频的姿态稳定控制与慢速的全局决策规划分离,避免不同控制目标间的耦合与干扰;其次,遵循“感知-规划-行动”的机器人学范式,将环境感知信息自上而下馈入控制回路,并将执行状态自下而上反馈以优化决策,形成自适应闭环。该系统集成运动学分析、控制矩阵、位姿稳定器及脚点优化器,其结构如图 1 所示。




图 1 巡检机器人三层协同控制系统架构示意图

由图 1 可知,层间推导与协同关系如下:上层落脚决策层基于栅格地图进行慢速全局优化,其输出(落脚点序列)作为中层姿态跟踪目标;中层位姿稳定层从中频尺度处理轨迹跟踪与振动抑制,其输出的平滑轨迹作为底层的位置指令;底层位移控制层负责高频关节运动的精确执行。同时,底层与中层的状态信息(如关节负载、姿态误差)可向上反馈,用于上层决策的在线修正。这种“自上而下指令传递”与“自下而上状态反馈”的协同机制,确保了系统在复杂环境中的可靠性、稳定性和适应性。

1.2 底层(位移控制层)设计

精准的运动学建模是机器人轨迹跟踪与位姿稳定的计算基础,能够决定机器人在复杂地形的性能。D-H 参数法能够构建关节坐标系链,显式表达位姿耦合关系,适配多自由度机构分析^[9]。因此,研究基于 D-H 参数法构建关节空间至操作空间的线性映射机制,以此生成位移控制矩阵,并将其作为三层协同控制系统的底层(位移控制层),D-H 参数法的映射流程如图 2 所示。




图 2 D-H 参数法的映射流程示意图

由图 2 可知, 研究通过 D-H 参数标定构建关节坐标链, 经正运动学解算机身位姿, 解析雅可比矩阵映射关系, 最终生成增量式位移控制矩阵。研究首先定义第 i 个关节的齐次变换矩阵 ${}^{i-1}T_i$ 如式(1) 所示:

$${}^{i-1}T_i = \begin{bmatrix} \cos\theta_i & -\sin\theta_i \cos\alpha_i & \sin\theta_i \sin\alpha_i & a_i \cos\theta_i \\ \sin\theta_i & \cos\theta_i \cos\alpha_i & -\cos\theta_i \sin\alpha_i & a_i \sin\theta_i \\ 0 & \sin\alpha_i & \cos\alpha_i & d_i \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (1)$$

式中, θ_i 为关节转动角度; a_i 为连杆长度; α_i 为连杆扭角; d_i 为连杆偏距。研究之后通过串联所有关节的齐次变换矩阵, 得到从基坐标系到末端执行器的总变换矩阵, 如式 (2) 所示:

$${}^0T_n = {}^0T_1 \cdot {}^1T_2 \cdot \dots \cdot {}^{n-1}T_n \quad (2)$$

式中, 0T_n 为基坐标系到末端执行器的位姿矩阵; n 为机器人的总关节数。该矩阵描述了末端执行器在笛卡尔空间中的位置与姿态信息^[10]。为实现对末端执行器的精确控制, 研究建立关节空间与操作空间之间的线性增量映射关系, 如式 (3) 所示:

$$\Delta x = J \cdot \Delta q \quad (3)$$

式中, Δx 为末端执行器在笛卡尔空间的位移增量向量; Δq 为关节角度增量向量; $J \in \mathbb{R}^{6 \times n}$ 为雅可比矩阵, 描述了末端执行器线速度与角速度对各关节角速度的灵敏度^[11]。当 $n = 6$ 时, 机器人具有全自由度控制能力; 当 $n > 6$ 时, 系统为冗余自由度机器人, 需引入加权最小范数法解决逆运动学问题。其通过构造目标函数 $\min_{\Delta q} \frac{1}{2} \|W \Delta q\|^2$ 并满足 $J \Delta q = \Delta d$ 的约束, 从而求得唯一解 $\Delta q = W^{-1} J^T (J W^{-1} J^T)^{-1} \Delta d$ 。其中 Δd 为末端执行器需要实现的、在笛卡尔空间中的位移增量; 加权矩阵 W 依据各关节运动特性设置为对角阵, 优先驱动运动范围大、惯性小的关节, 在保证精确定位的同时实现更平滑、稳定的关节运动。

研究基于 D-H 参数法建立巡检机器人多自由度运动学链模型, 通过串联关节变换矩阵解算机身全局位姿。创新设计位移控制矩阵实现关节空间至操作空间的线性映射, 为轨迹跟踪提供高精度底层控制接口。该方法形成位姿解算与位移控制的闭环架构, 为复杂地形运动稳定性奠定数学基础。传统 D-H 运动链在复杂地形

应用中存在显著局限: 当机器人跨越陡坡与沟壑交界区域时, 由于缺乏地形梯度感知, 关节位移控制无法预判坡面形变对运动学解算的影响, 导致末端执行器位姿解算累积误差增大。为突破此瓶颈, 研究创新融合上层落脚决策层的栅格高程梯度信息, 提出地形自适应补偿机制。定义坡面形变影响因子如式 (4) 所示:

$$\kappa_g = 1 + \lambda \|\nabla z_{\text{target}}\| \quad (4)$$

式中, ∇z_{target} 为目标落脚点梯度向量 (由上层决策层实时提供); λ 为地形耦合系数 (通过机器人质量分布和地面摩擦特性标定)。重构位移控制增量方程如式 (5) 所示:

$$\Delta \theta' = \kappa_g \cdot \Delta \theta + J^{-1}(\theta) \cdot T_{\text{comp}} \quad (5)$$

式中, $\Delta \theta'$ 为修正后的关节位移增量向量; $\Delta \theta$ 为原始运动学逆解计算得到的关节位移增量; $J^{-1}(\theta)$ 为雅可比矩阵的逆, 将末端执行器所需的运动空间转换为各关节的角位移; $T_{\text{comp}} = [0, 0, \delta_z, 0, 0, 0]^T$ 为高程补偿向量 ($\delta_z = \beta \cdot \frac{\partial z}{\partial s}$ 由路径高程变化率生成)。该策略通过梯度数据动态调节关节位移增量, 使底层控制具备地形预适应能力。其核心优势在于建立上层感知信息与底层运动学解算的融合通道, 当检测到陡坡区域 ($\|\nabla z\|$ 增大) 时, 自动增强高程补偿强度, 确保位移控制矩阵输出的位姿指令与地形特征精确匹配, 为中层位姿稳定层提供高质量输入基准。

1.3 中层 (位姿稳定层) 设计

研究建立的 D-H 运动学链模型及关节—末端位移映射机制 (底层), 能够作为轨迹跟踪的底层运动控制基准。此外, 平滑轨迹规划是抑制机身姿态振荡的关键前提, 而五次多项式能够生成连续可导路径, 消除加速度突变, 避免关节冲击性负载^[12]。因此, 研究基于五次多项式轨迹耦合 MPC 构建位姿稳定器, 并将其作为三层协同控制系统的中层 (位姿稳定层), 位姿稳定器结构如图 3 所示。




图 3 位姿稳定器结构

由图 3 可知, 位姿稳定器通过 5 次多项式生成平滑参考轨迹, 经 MPC 滚动优化实时校正姿态角偏差, 最终输出抗扭转关节控制量。研究首先采用 5 次多项式生成期望轨迹来实现关节运动的平滑性与连续性, 如式 (6) 所示:

$$q_d(t) = \sum_{k=0}^5 a_k t^k \quad (6)$$

式中, $\mathbf{q}_d(t)$ 为关节期望角度 (或位移) 向量; $\mathbf{a}_k$ 为多项式系数向量 (共 6 个自由度); t 为时间变量。研究通过设定起始 (0) 与终止时刻 (t_f) 的位置 θ 、速度 $\dot{\theta}$ 、加速度 $\ddot{\theta}$ 条件, 从而生成满足边界约束的光滑轨迹^[13], 其约束如式 (7) 所示:

$$\begin{cases} \theta(0) = \theta_0, & \dot{\theta}(0) = \dot{\theta}_0, & \ddot{\theta}(0) = \ddot{\theta}_0 \\ \theta(t_f) = \theta_f, & \dot{\theta}(t_f) = \dot{\theta}_f, & \ddot{\theta}(t_f) = \ddot{\theta}_f \end{cases} \quad (7)$$

求解式 (7) 的线性方程组可唯一确定多项式系数 $\mathbf{a}_k$ 。由此生成的轨迹在位置、速度、加速度层面均连续, 从源头上避免了因加速度突变引起的关节冲击和机身振动。之后, 针对巡检机器人机身姿态控制问题, 研究建立姿态角的动力学状态空间模型, 如式 (8) 所示:

$$\dot{\mathbf{x}} = \begin{bmatrix} \dot{\theta} \\ \ddot{\theta} \end{bmatrix} = \mathbf{A}\mathbf{x} + \mathbf{B}\mathbf{u} \quad (8)$$

式中, $\mathbf{x}$ 为状态变量 ($\mathbf{x} = [\theta, \dot{\theta}]^T$); $\mathbf{u}$ 为姿态角向量, 包含俯仰角与横滚角; $\dot{\theta}$ 为姿态角速度。 $\mathbf{u}$ 为关节控制力矩输入。系统矩阵 $\mathbf{A}$ 与输入矩阵 $\mathbf{B}$ 由机身动力学特性决定, 用于构建线性时变系统模型。MPC 的核心是在每个采样时刻, 基于当前状态 $\mathbf{x}(k)$, 对未来有限时域 N_p 步的系统状态进行预测, 并通过求解一个优化问题来得到最优控制序列 $\mathbf{u}(k), \mathbf{u}(k+1), \dots, \mathbf{u}(k+N_c-1)$ (N_c 为控制时域), 仅将序列中的第一个控制量 $\mathbf{u}(k)$ 施加于系统。在下一时刻, 重复此过程, 实现“滚动优化”。因此, 为实现姿态角的高精度跟踪与控制输入的优化分配, 研究设计 MPC 目标函数, 如式 (9) 所示:

$$\min_{\mathbf{u}} \int_t^{t+T} \|\mathbf{x}_{\text{ref}} - \mathbf{x}\|_Q^2 + \|\mathbf{u}\|_R^2 dt \quad (9)$$

式中, $\mathbf{x}_{\text{ref}}$ 为参考姿态角轨迹向量; $\mathbf{Q}$ 为状态误差加权矩阵; $\mathbf{R}$ 为控制输入加权矩阵; T 为预测时域长度。该目标函数旨在最小化预测时域内的状态跟踪误差与控制能量消耗。其约束于系统的动力学模型以及 $\mathbf{u}_{\min} \leq \mathbf{u}(k+i) \leq \mathbf{u}_{\max}$ (控制量约束; $i = 0, 1, \dots, N_c - 1$)、 $\Delta\mathbf{u}_{\min} \leq \Delta\mathbf{u}(k+i) \leq \Delta\mathbf{u}_{\max}$ (控制增量约束, 进一步平滑控制输出; $i = 0, 1, \dots, N_c - 1$)、 $\mathbf{x}_{\min} \leq \mathbf{x}(k+i) \leq \mathbf{x}_{\max}$ (状态量约束; $i = 1, 2, \dots, N_p$)。通过求解该带约束的二次规划问题, 获得最优控制输入 $\mathbf{u}^*$ ^[14]。研究通过五次多项式预生成加速度连续轨迹, 从源头避免关节运动突变; 进而设计模型预测控制器滚动优化机身姿态角动态, 实时校正横滚与俯仰偏差。现有位姿稳定器在应对落脚点突变时存在控制滞后问题: 标准 MPC 架构依赖姿态角偏差反馈信号, 无法在坡度骤变前预先生成抑制力矩。为此, 研究设计梯度前馈—状态反馈协同机制, 如图 4 所示。

由图 4 可知, 该机制通过引入上层地形梯度前馈信息, 使位姿稳定控制器具备坡度扰动预测能力, 结合中层状态反馈实现增益自适应, 形成预测—校正协同机制, 显著提升系统对突发地形变化的动态响应与抑振性




图 4 梯度前馈—状态反馈协同机制示意图

能。首先构建前馈补偿项, 如式 (10) 所示:

$$\mathbf{d}(k) = \mathbf{K}_f \cdot \nabla \mathbf{z}_{\text{next}}(k) \quad (10)$$

式中, $\mathbf{d}(k)$ 为在离散时间步 k 引入的状态空间前馈补偿向量; $\nabla \mathbf{z}_{\text{next}}$ 为下一落脚点梯度向量 (由决策层提前 150 ms 发送); $\mathbf{K}_f$ 为前馈增益矩阵 (通过动力学参数辨识确定)。据此, 增强状态空间方程, 同时引入中层实时姿态角偏差 $\mathbf{e}_{\text{att}}$ 实现增益自适应, 如式 (11) 所示:

$$\begin{cases} \mathbf{x}(k+1) = \mathbf{A}(k)\mathbf{x}(k) + \mathbf{B}(k)\mathbf{u}(k) + \mathbf{d}(k) \\ \mathbf{K}_f = \mathbf{K}_{f0} \cdot (1 + \mu \|\mathbf{e}_{\text{att}}\|) \end{cases} \quad (11)$$

式中, $\mathbf{x}(k+1)$ 为系统在时刻 k 的状态向量 (如位姿、速度、姿态角等); $\mathbf{A}(k)$ 为状态转移矩阵; $\mathbf{u}(k)$ 为控制输入向量 (如关节力矩、驱动力等); $\mathbf{B}(k)$ 为输入矩阵, 表示控制输入对状态的影响方式; $\mathbf{e}_{\text{att}} = [\Delta\phi, \Delta\psi]^T$ 为中层实时姿态角偏差; μ 为灵敏度系数。该改进通过上层地形信息前馈与中层状态反馈形成闭环, 使位姿稳定器在机身抵达陡坡前预生成抗俯仰力矩。其结构优势在于创建“决策层→稳定层”的预警通道, 将地形感知转化为前馈控制量, 配合反馈调节形成预测—校正双模抑振机制, 显著提升系统对未知地形扰动的适应能力。

1.4 上层 (落脚决策层) 设计

研究建立的位姿稳定器 (中层) 能够提供崎岖地形下的位姿动态稳定保障, 但其输出需结合上层地形感知信息才能完成落脚决策闭环。落脚点全局优化是坡面自适应运动的决策核心, 而栅格高程图能够量化坡面梯度分布, 精准辨识非结构地形安全支撑域^[15]。因此, 研究基于栅格高程图, 设计梯度引导决策, 来构建落脚点优化器, 并将其作为 3 层协同控制系统的上层 (落脚决策层)。首先, 通过机器人搭载的激光雷达实时采集周围环境的三维点云数据。随后, 将机器人所在的水平面 (X - Y 平面) 划分为分辨率为 0.01 m 的均匀网格。对于每个栅格 (i, j) , 其高程值 $z_{i,j}$ 通过落入该栅格的所有点云数据的高度值 (Z 坐标) 取算术平均得到, 从而形成数字高程模型, 如式 (12) 所示:

$$\mathbf{Z}_{\text{grid}} = \begin{bmatrix} z_{11} & \cdots & z_{1n} \\ \vdots & \ddots & \vdots \\ z_{m1} & \cdots & z_{mn} \end{bmatrix} \quad (12)$$

式中, 地图分辨率为 $m \times n$, 即行数 $\times$ 列数。为评估每

个栅格点的坡度和坡向, 需计算其局部梯度向量。研究采用中心差分法计算栅格 (i, j) 在 X 和 Y 方向上的偏导数 $\frac{\partial z}{\partial x}$ 和 $\frac{\partial z}{\partial y}$, 进而得到梯度向量 $\nabla z_{i,j}$ [16], 如式 (13) 所示:

$$\nabla h_{ij} = \left(\frac{\partial z}{\partial x}, \frac{\partial z}{\partial y} \right)_{ij} \approx \left(\frac{z_{i+1,j} - z_{i-1,j}}{2\Delta x}, \frac{z_{i,j+1} - z_{i,j-1}}{2\Delta y} \right)$$

(13)

式中, $\|\nabla h_{ij}\|$ 为梯度模长, 对应该点的坡度角 θ ; $(\Delta x, \Delta y)$ 为栅格在 x, y 方向上的空间分辨率。而落脚点决策的目标是在栅格地图上搜索从起点到目标点的最优安全序列 $P = \{p_1, p_2, \dots, p_n\}$, 在满足运动可达性的前提下最小化全局坡度以抑制滑移。该问题被建模为路径总代价最小化问题, 相邻点 $p_k = (i_k, j_k)$ 间的代价函数定义如式 (14) 所示:

$$c(p_k, p_{k+1}) = \omega_1 \cdot \|\nabla z_{p_{k+1}}\| + \omega_2 \cdot \|p_{k+1} - p_k\|$$

(14)

式中, $\|\nabla z_{p_{k+1}}\|$ 为目标点坡度模长, $\|p_{k+1} - p_k\|$ 为步幅距离, ω_1, ω_2 为权重。优化目标是求解总代价最小的序列 P , 如式 (15) 所示:

$$\{P_k\}^* = \underset{\{P_k\}}{\operatorname{argmin}} \sum_{k=1}^N \|\nabla h(P_k)\|$$

(15)

式中, N 为候选落脚点数量; 通过最小化总梯度模长之和, 能够降低机器人行走过程中的滑移风险, 提升行走稳定性[17]。该优化问题通过 Dijkstra 算法求解。将每个栅格视为图中的一个节点, 节点间的边权由代价函数 $c(p_k, p_{k+1})$ 定义, 即可搜索出从起点到终点的最优 (或次优) 落脚点序列。经过以上计算, 落脚决策层通过栅格高程模型解析地形梯度场, 评估支撑域抗滑移稳定性, 最终生成最优落脚点序列, 供位移控制层和中层执行。传统落脚点优化策略存在系统性缺陷: 仅考虑坡度最小化而忽略底层关节运动能力约束和中层振动状态, 导致部分规划路径超出执行机构物理极限。为此, 研究提出运动-状态双约束优化策略, 如图 5 所示。




图 5 运动-状态双约束优化策略

由图 5 可知, 该策略融合底层运动学约束与中层振动状态反馈, 构建动态调整的多目标优化框架, 使落脚点选择不仅考虑地形坡度, 更兼顾执行可行性与整机稳

定性, 实现全局最优的步态规划决策。首先定义综合代价函数, 如式 (16) 所示:

$$C(p_k) = w_g \|\nabla z_{p_k}\| + w_k \|J^{-1}(\theta)(x_{p_k} - x_{\text{current}})\|_2 + w_v \|\ddot{\psi}\|_{p_k}$$

(16)

式中, $\|J^{-1}(\cdot)\|_2$ 评估关节空间运动代价 (基于底层反馈); $\|\ddot{\psi}\|_{p_k}$ 为落脚点 p_k 处历史姿态角加速度均值 (来自中层数据流)。权重根据系统状态动态调整, 如式 (17) 所示:

$$\begin{cases} w_v = \eta_v \sigma(\|\omega\|) \\ w_k = \eta_k \rho[\text{cond}(J)] \end{cases}$$

(17)

式中, $\sigma(\cdot)$ 和 $\rho(\cdot)$ 为特征映射函数。该策略通过三层信息融合, 使落脚决策同时满足坡度安全性、运动可行性和执行稳定性需求。其创新性在于构建“控制层/稳定层→决策层”的闭环反馈通路, 当底层报告关节接近运动极限 $[\text{cond}(J)$ 增大] 或中层检测异常振动时, 自动降低对应权重, 确保生成步态序列符合系统全局优化目标。

2 油气田巡检机器人结果分析

2.1 实验环境设置

研究采用搭载 Intel Core i9-12900K 处理器及 NVIDIA RTX 3090 显卡的工业控制机, 配备 64 GB DDR5 内存。系统的运行载体为 Go2 四足机器人。该平台集成 Hokuyo UST-20LX 激光雷达与 Xsens MTi-670 惯性测量单元, 其原生关节伺服系统定位精度 $\pm 0.05^\circ$ 。软件环境为 Ubuntu 20.04 LTS 操作系统, ROS Noetic 框架, Gazebo 11.0 物理引擎, Matlab 2023a 控制系统仿真平台, 自主开发控制器库 (C++11/Python3.8)。其上层落脚决策层在 ROS 中接收激光雷达点云, 实时构建栅格高程图并求解最优落脚点序列; 中层位姿稳定层在 Matlab/Simulink 中生成五次多项式轨迹并求解 MPC 问题, 编译为 C++ 代码后通过 ROS 发布关节控制指令; 底层位移控制层通过 ROS 节点接收指令, 由嵌入式伺服驱动器执行高精度关节运动。各层运算频率分别为 10 Hz、100 Hz 与 1 kHz, 通过 ROS 话题与服务进行跨层数据交互, 形成闭环。

研究在 Gazebo 11.0 中搭建了油气田巡检模拟测试环境, 通过 DEM 数据构建了包含 $0 \sim 20^\circ$ 坡度、沟壑及碎石的非结构化地形, 并设置了管道、阀组等典型障碍。为模拟真实扰动, 添加了振幅 $0.5 \sim 2.0$ mm 的机械振动源和周期性热蒸汽泄漏点, 复现了复杂地形与动态干扰环境。该环境地形模型源于实际勘测数据, 复现了导致打滑、失稳的主要因素; 机械振动与热扰动模拟了管道运行与泄漏工况; 巡检路径与任务要求高度还原真实作业流程, 有效验证了系统在典型油气田环境下的性能。参数设置方面, 机器人机身尺寸约为 $0.6 \times 0.3 \times 0.4$ m (长 $\times$ 宽 $\times$ 高), 12 自由度关节 (髋关节扭矩

极限典型值 ± 35 Nm), 为适应油气田巡检的负载需求, 研究为其加装了防护外壳及传感器模块, 总质量增加至约 22 kg。控制参数中, MPC 预测时域 $T=0.8$ s, 采样周期 $\Delta t=0.05$ s。并且, 研究选择线性二次调节器 (LQR, linear quadratic regulator)^[18]、自适应模型预测控制 (A-MPC, adaptive model predictive control)^[19]、软演员—评论者强化学习 (SAC, soft actor-critic)^[20] 以及基于最优快速扩展随机树轨迹的 MPC (RMPC, MPC based on optimal rapidly-exploring random tree trajectory)^[21] 作为研究系统 (Ours) 的对比方法。对比方法的参数设置与文献中设置一致。研究通过 ROS 话题同步记录机身位姿 (源自 IMU 与关节编码器)、伺服电机输出的关节力矩, 以及通过足端传感器与 Gazebo 插件获取的环境交互数据 (包括接触力与地面反作用力) 等, 继而完成性能指标对比。

2.2 巡检机器人运动测试结果

在仿真测试中, 为全面评估系统性能, 研究设置了多项典型巡检任务 (任务编号 0—30) 以覆盖不同难度与场景。研究首先对比不同方法的位移跟踪绝对误差均值 (MAPE, mean absolute position error) 和姿态角振荡幅度 (AOA, attitude oscillation amplitude), 来衡量其轨迹跟踪精度与动态稳定性, 如图 6 所示。




图 6 MAPE 及 AOA 差异验证

由图 6 (a) 可知, Ours 的 MAPE 以 0.018 cm 逼近理论极限, 最大值 0.032 cm 高于 SAC 最小值 0.026 cm 却显著低于其他方法下限。A-MPC 最大值 0.051 cm 佐证环境感知缺失, LQR 波动剧烈。研究方法的位移控制层 (底层) 经 D-H 运动链精密解算, 雅可比映射抑制关节误差传播, MAPE 波动值 0.014 cm 为全算法最窄 ($p<0.001$)。由图 6 (b) 可知, Ours 振荡幅度以 1.1° 创全局最优, 最大值 3.1° 虽高于 A-MPC 最小值 2.1°, 仍显著优于其他方法。RMPC 最大振荡 5.6° 暴露无约束轨迹规划缺陷, 而 SAC 波动剧烈。研究方法的中层 (位姿稳定层) 融合多项式轨迹平滑性, 上层 (落脚决策层) 高程引导落脚点优化削弱地形扰动耦合, AOA 标准差 0.53° 为全算法最低 ($p<0.001$)。之后研

究对比, 不同方法的俯仰角摆动角度 (POA, pitch oscillation angle) 和爬坡误差率 (CER, climbing error rate), 来评估其转向稳定性与斜坡适应性, 如图 7 所示。




图 7 POA 及 CER 差异验证

由图 7 (a) 可知, Ours 的 POA 以 0.005 rad 创全局最优, 最大值 0.020 rad 虽高于 SAC 最小值 0.017 rad, 仍显著优于其他方法。RMPC 峰值 0.060 rad 暴露无环境感知缺陷, 而 A-MPC 波动剧烈。研究方法的落脚决策层 (上层) 融合中层 (位姿稳定层) MPC 姿态前馈, 通过栅格高程梯度预判坡角变化, 抑制机身俯仰耦合振荡, POA 标准差 0.005 rad 为全算法最低 ($p<0.001$)。由图 7 (b) 可知, Ours 的 CER 以 1.1% 突破理论极限低值, 其最大值 2.4% 高于 LQR 最小值 2.2% 却远低于他法下限。SAC 峰值 5.7% 佐证学习策略泛化不足, RMPC 剧烈波动。研究方法的位移控制层 (底层) 经雅可比逆解精密映射, 关节空间至操作空间零累计误差传递保障坡度自适应, CER 极差 1.3% 为全算法最窄 ($p<0.001$)。为进一步探究不同方法的性能和稳定性, 研究进行单次控制循环运行时间及迭代效率对比验证。其中 LQR 基于状态空间模型的解析解, 计算不依赖问题规模, 且没有迭代过程, 因此不参与验证, 结果如图 8 所示。




图 8 算法效率及性能验证

由图 8 (a) 可知, Ours 运行时间从 5.2 ms (100 栅格) 增至 28.9 ms (10 000 栅格), 增幅 5.6 倍, 远低于 RMPC 的 28.3 倍 (45.3~1 280.5 ms)。A-MPC 呈线性增长至 72.8 ms, SAC 保持稳定 (8.7~10.1 ms)。

Ours 通过上层局部梯度计算与中层固定时域优化，实现计算效率规模不敏感 ($p<0.001$)。由图 8 (b) 可知，Ours 控制精度达 99.7%，40 次迭代时 92.3% 显著优于 A-MPC (78.6%)、SAC (82.5%) 和 RMPC (63.8%)。3 层架构通过底层位移映射与中层抑振优化，保障快速收敛与稳定 ($p<0.001$)。之后，为验证系统在实际环境中的运动控制性能，研究选择坡度 0~25° 的管廊弯道、碎石滩及高温蒸汽泄漏区进行实测验证。该场地覆盖非结构化路面突变、动态热扰动与视觉遮挡复合干扰环境。实测验证的实验结果如表 1 所示。

表 1 实测性能验证

方法		Ours	LQR	A-MPC	SAC	RMPC
MAPE/cm	均值	0.021	0.038	0.047	0.035	0.052
	标准差	0.004	0.007	0.009	0.008	0.011
AOA/ (°)	均值	1.8	3.5	3.1	4.2	4.9
	标准差	0.4	0.9	0.7	1.2	1.5
POA/rad	均值	0.012	0.031	0.028	0.025	0.042
	标准差	0.003	0.006	0.007	0.009	0.01
CER/%	均值	1.8	3.2	4.1	3.8	5.3
	标准差	0.3	0.8	1.1	1.3	1.6

由表 1 可知，研究方法 (Ours) 在实测中展现全面优势：MAPE 均值 0.021 cm (标准差 0.004 cm) 较最优对比方法 SAC 降低 40%，轨迹跟踪精度波动全场景最小。AOA 均值 1.8° (标准差 0.4°) 印证中层位姿稳定层融合上层落脚决策层优化的协同抗扰能力，较 LQR 振荡幅度降低 48.6%。POA 均值 0.012 rad (标准差 0.003 rad) 满足 ≤ 0.02 rad 设计约束，中层 MPC 前馈补偿有效抑制俯仰耦合。此外，研究方法的 CER 均值 1.8% (标准差 0.3%) 突破 2.5% 阈值，底层位移控制层保障坡度自适应精度。各指标 $p<0.001$ 验证三层协同控制系统的工程显著性。

3 结束语

针对突变地形下姿态稳定与落脚点协同优化难题，研究提出基于三层协同控制系统的环境—运动融合控制架构。通过位移控制层 (底层)、位姿稳定层 (中层) 及落脚决策层 (上层) 三级协同，实现机身抑振与坡面自适应的动态平衡。实验表明，该系统在复杂地形中实现毫米级轨迹跟踪精度 (MAPE 波动 $< \pm 0.004$ cm)，机身振荡幅度压缩至传统方法的 48.6% (AOA 均值 1.8°)。落脚决策层 (上层) 通过梯度场解析降低滑移风险，爬坡误差率稳定于 1.8% (低于 2.5% 阈值)，POA 波动范围 0.009~0.015 rad 验证中层位姿稳定层俯仰控制有效性。模型创新性在于构建“感知—决策—控制”闭环耦合的三层协同机制：底层 D-H 运动链保障位姿解算保真度，中层 MPC 滚动优化实现动态抑振

前馈，上层栅格梯度场为落脚决策提供地形动力学先验知识。然而研究的局限性在于落脚决策层 (上层) 依赖栅格高程图的静态表征，在动态形变地形中梯度场解算误差增大，导致坡面自适应能力下降。针对以上问题，研究的未来工作是融合毫米波雷达与视觉的实时地形变感知模块，构建动态—静态融合梯度场融入上层落脚决策层；并研发落脚点在线重规划策略，增强三层协同控制系统的非稳态地质环境适应性。

参考文献：

[1] 肖云发，韩 芳，王青云. 基于脉冲强化学习和 CPG 的四足机器人分层运动控制 [J]. 控制与决策, 2025, 40 (7): 2070–2078.

[2] 黄小霞，阳 波，向 鑫，等. 基于改进行为克隆算法的机器人运动控制策略 [J]. 计算机应用研究, 2025, 42 (6): 1668–1675.

[3] 张俊娜，白国星. 基于速度调节与路径跟踪的差动机器人运动控制 [J]. 工程科学学报, 2023, 45 (9): 1550–1558.

[4] QASIM M, AYOUB A B, ABDULLA A I. NMPC based-trajectory tracking and obstacle avoidance for mobile robots [J]. International Journal of Robotics & Control Systems, 2024, 4 (4): 2026–2040.

[5] 谢子健，秦建军，曹 钰. 基于改进 TD3 的四足机器人非结构化地形运动控制 [J]. 现代制造工程, 2025 (1): 33–41.

[6] HALDAR A I, PAGAR N D. Predictive control of zero moment point (ZMP) for terrain robot kinematics [J]. Materials Today: Proceedings, 2023, 80 (1): 122–127.

[7] 苏 毅，吴文欢，李鼎鑫. 基于双分辨率栅格地图的机器人路径规划研究 [J]. 仪器仪表学报, 2025, 46 (3): 86–100.

[8] JAKKALA K, AKELLA S. Multi-robot informative path planning from regression with sparse Gaussian processes [C] //2024 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2024: 12382–12388.

[9] 何 涛，王 超，杨雨升. 基于改进 D-H 的隧道摄像头清洗机器人运动学分析 [J]. 机械与电子, 2024, 42 (8): 50–56.

[10] ZHANG C, ZHOU L, LI Y. Pareto optimal reconfiguration planning and distributed parallel motion control of mobile modular robots [J]. IEEE Transactions on Industrial Electronics, 2023, 71 (8): 9255–9264.

[11] 张润宁，余 鹏，谭 宁. 基于变参递归网络和递归最小二乘的连续体机器人控制 [J]. 自动化学报, 2025, 51 (1): 90–103.

[12] 刘修成，董奇峰，纪晓宇，等. 液压驱动型水下掘进机器人臂架运动控制研究 [J]. 中国工程机械学报, 2023, 21 (6): 590–595.

(下转第 243 页)

电混合分布式推进系统供电网络与电源管理研究及集成验证”项目, 为了对混电推进系统进行测试, 本文借助 LabVIEW 软件, 设计了混电推进系统的上位机。该上位机可对混电推进系统进行控制, 并能采集系统运行过程中的多种参数, 具体包括对直流母线、电动机、发电机、电池、DC/DC 运行参数及系统故障信息进行采集, 并完成波形图的显示。数据保存功能为数据的记录及对比提供了便利。实验结果显示, 作为混电推进系统的上位机, 该上位机具有工程推广应用价值。

参考文献:

[1] 王妙香, 王元元. 电动飞机的误解分析与研究综述 [J]. 航空科学技术, 2019, 30 (5): 3-8.

[2] 张小伟. 蓄势待发的新一轮动力革命 [J]. 大飞机, 2014 (6): 38-41.

[3] 朱炳杰, 杨希祥, 宗建安, 等. 分布式混合电推进飞行器技术 [J]. 航空学报, 2022, 43 (7): 48-64.

[4] 李嘉诚, 盛汉霖, 陈 欣, 等. 混合动力分布式电推进飞行器总体设计 [J]. 航空动力学报, 2024, 39 (9): 156-168.

[5] RENDÓN M A, SANCHEZ R C D, GALLO M J, et al. Aircraft hybrid-electric propulsion: Development trends, challenges and opportunities [J]. Journal of Control, Automation and Electrical Systems, 2021, 32 (5): 1244-1268.

[6] OELBERG E. A hybrid optimal control approach to maximum endurance of aircraft [D]. Concordia University, 2018.

[7] 廖忠权. 2022 世界电动系统进展 [J]. 航空动力, 2023 (1): 23-26.

[8] 高 杨. NASA 电气化飞机推进系统控制方案分析 [J]. 航空动力, 2023 (2): 34-38.

[9] BRELJE J B, MARTINS R J. Electric, hybrid, and tur-

[13] MAKIN T R, MICERA S, MILLER L E. Neurocognitive and motor-control challenges for the realization of bionic augmentation [J]. Nature Biomedical Engineering, 2023, 7 (4): 344-348.

[14] 秦海鹏, 秦 瑞, 施晓芬, 等. 基于模型预测的四足机器人运动控制 [J]. 浙江大学学报 (工学版), 2024, 58 (8): 1565-1576.

[15] ZHENG H, LU Y, JIE J, et al. Gaussian adaptive strategy based multi-objective evolutionary optimization for path planning on uneven terrains [J]. IEEE Robotics and Automation Letters, 2023, 9 (1): 539-546.

[16] 金书奎, 寇子明, 吴 娟. 煤矿水泵房巡检机器人路径规划与跟踪算法的研究 [J]. 煤炭科学技术, 2022, 50 (5): 253-262.

boelectric fixed-wing aircraft: a review of concepts, models, and design approaches [J]. Progress in Aerospace Sciences, 2018, 104 (C): 1-19.

[10] 廖忠权. 航空混合电推进系统发展研究 [J]. 航空动力, 2018 (2): 45-50.

[11] 秦 江, 姬志行, 郭发福, 等. 航空用燃料电池及混合电推进系统发展综述 [J]. 推进技术, 2022, 43 (7): 6-23.

[12] 李正浩. 通用飞机油电混合动力系统优化与仿真 [D]. 沈阳: 沈阳航空航天大学, 2016.

[13] 康桂文, 孙振祥. 通用飞机油电混合动力系统设计与性能仿真 [J]. 沈阳航空航天大学学报, 2015, 32 (2): 23-27.

[14] 雷 涛, 孔德林, 王润龙, 等. 分布式电推进飞机动力系统评估优化方法 [J]. 航空学报, 2021, 42 (6): 44-63.

[15] 刘一雄, 莫 姐. 一种混合动力航空发动机及其优化设计方法 [P]. 中国: CN202210406872. 2, 2022-07-12.

[16] 张小伟. 面向 2030 年的分布式混合电推进技术 [C] // 北京: 中国航空工业发展研究中心, 2015: 5.

[17] 李晓锦, 王红磊, 倪计民, 等. 一种基于 LABVIEW 的混合动力汽车新型上位机平台的设计 [J]. 汽车工程, 2013, 35 (4): 312-316.

[18] 黄丽莹. 油电混合动力系统配置优化及仿真监控设计 [D]. 北京: 北京交通大学, 2022.

[19] 邵 斌, 朱茂桃, 张 彤, 等. 混合动力汽车 CAN 网络信号监测与故障诊断系统的开发 [J]. 汽车技术, 2009 (2): 46-50.

[20] ZHAN W, PORTER J R, MORGAN J A. Experiential learning of digital communication using LabVIEW [J]. IEEE Transactions on Education, 2014, 57 (1): 34-41.

[17] 吴聪懿, 徐云浪, 陈椿元, 等. 基于物理引导的 RBF 神经网络逆模型在 ZTT 运动平台前馈控制中的应用 [J]. 动力学与控制学报, 2025, 23 (1): 78-85.

[18] 吴 量, 顾义凡, 邢 彪, 等. 基于线性二次型调节器的四轮转向与分布式集成控制方法 [J]. 吉林大学学报 (工学版), 2024, 54 (9): 2414-2422.

[19] 吴永刚, 梁华为. 基于自适应模型预测的无人车跟踪控制方法研究 [J]. 制造业自动化, 2023, 45 (2): 198-202.

[20] 杨梓豪, 王庆领. 基于分层强化学习的多无人机协同围捕方法 [J]. 海军航空大学学报, 2025, 40 (4): 567-575.

[21] 周 维, 过学迅, 裴晓飞, 等. 基于 RRT 与 MPC 的智能车辆路径规划与跟踪控制研究 [J]. 汽车工程, 2020, 42 (9): 1151-1158.