

基于灰狼优化的自适应混合A*和人工势场的无人矿卡路径规划研究

韩彦岭¹, 吕金科¹, 周国峰², 张力珂¹, 张云¹

(1. 上海海洋大学信息学院, 上海 201306;

2. 上海海洋大学工程学院, 上海 201306)

摘要: 为了提升无人驾驶技术在露天矿区应用中的路径规划能力, 提出了一种基于灰狼优化的自适应混合A*和人工势场 (grey wolf optimization-based adaptive hybrid A* and artificial potential field, GWO-HAPF) 方法。通过灰狼优化算法对混合A*的关键参数进行自适应调整, 实现路径长度、平滑度和规划时间的多目标平衡, 从而克服混合A* (hybrid A*, HA*) 算法固定参数适应性不足的问题, 大幅提升了全局路径规划的质量与适应性。在局部路径规划中, 采用改进的人工势场法, 优化斥力函数并增加逃出力, 有效提升了实时避障的可行性和路径的平滑性。实验结果表明, 相较于HA*算法和改进HA* (improved hybrid A*, IHA*) 算法, GWO-HAPF方法在全局规划中的计算效率分别平均提升了约80%和14.9%, 路径长度平均减少9.8%, 平滑度平均提升超过53%; 在局部路径规划中, 其规划时间相较于IHA*算法提升了95.8%, 平滑度为IHA*算法的10.19%, 能够高效完成避障任务。研究结果表明, 该方法在规划效率、路径长度、平滑性和实时避障方面表现出优势, 体现了其在露天矿区无人矿卡路径规划中的实际应用价值。

关键词: 路径规划; 灰狼优化; 自适应混合A*; 人工势场; 无人矿卡

中图分类号: TP39

文献标志码: A

doi: 10.11959/j.issn.2096-6652.202513

Research on unmanned mining truck path planning based on grey wolf optimization adaptive hybrid A* and artificial potential field

HAN Yanling¹, LYU Jinke¹, ZHOU Guofeng², ZHANG Like¹, ZHANG Yun¹

1. College of Information Technology, Shanghai Ocean University, Shanghai 201306, China

2. College of Engineering Science and Technology, Shanghai Ocean University, Shanghai 201306, China

Abstract: To enhance the path planning capabilities of unmanned mining trucks in open-pit mining scenarios, a grey wolf optimization-based adaptive hybrid A* and artificial potential field (GWO-HAPF) method was proposed. The proposed method employed the grey wolf optimization algorithm to adaptively adjust the key parameters of the hybrid A* (HA*) algorithm, achieving a multi-objective balance among path length, smoothness, and planning time. This effectively overcame the HA* algorithm's limited adaptability to fixed parameter settings, significantly improving the quality and adaptability of global path planning. For local path planning, an improved artificial potential field method was adopted, optimizing the repulsive force function and incorporating an escape force mechanism, which effectively enhanced real-time obstacle avoidance feasibility and path smoothness. Experimental results demonstrate that, compared to the standard HA* algorithms and the improved hybrid A* (IHA*) algorithms, GWO-HAPF improves computational efficiency in global planning by an average of 80% and 14.9%, respectively, reduces path length by over 9.8%, and increases smoothness by over 53%. In local path planning, GWO-HAPF achieves a planning time that is 95.8% shorter than IHA*, while its smoothness improves to 10.19% of IHA*. These findings indicate that the proposed method exhibits outstanding advan-

收稿日期: 2024-11-28; 修回日期: 2025-03-04

基金项目: 国家自然科学基金项目 (No.42176175, No.42271335)

Foundation Item: The National Natural Science Foundation of China (No.42176175, No.42271335)

tages in planning efficiency, path length, smoothness, and real-time obstacle avoidance, showcasing its practical application value in path planning for unmanned mining trucks in open-pit mining scenarios.

Key words: path planning, grey wolf optimization, adaptive hybrid A*, artificial potential field, unmanned mining truck

0 引言

露天矿区无人驾驶技术的应用不仅为矿山行业的生产效率带来了巨大提升,也在安全性、成本控制等方面具有重要意义。与传统人工驾驶相比,无人驾驶系统能够在矿区这种危险的环境中实现全天候、高效率的作业^[1-5]。作为无人驾驶技术的核心,路径规划技术旨在为车辆提供一条从起点到终点的最优路径,确保路径的安全性、平滑性以及实时适应性^[6]。根据任务的不同需求,路径规划通常分为全局路径规划和局部路径规划两类。全局路径规划基于已知环境信息,生成从初始位置到目标位置的可行路径,而局部路径规划则依据局部环境信息对路径进行调整,以实现避障和安全行驶。

全局路径规划算法中,A*算法及其变体被广泛应用,而由于采用离散化搜索策略,其在复杂场景中生成的路径较为曲折,难以满足实际车辆的运动学约束^[7]。混合A*(hybrid A*, HA*)算法通过在A*算法的搜索过程中引入运动学约束,使生成的路径能够满足车辆的运动学模型^[8],在无人矿卡路径规划中具备一定适用性。近年来,研究者们对HA*算法进行了改进。邓穆坤等^[9]提出了一种专为无人驾驶矿区卡车设计的HA*搜索方法,有效提升了矿区路径规划的成功率。然而,该方法在参数调节上仍依赖经验值,缺乏灵活性。Tu等^[10]则通过限制搜索过程中的反向扩展来提升计算速度,但仍要面临局部最优问题和参数调节的困难。陈鑫鹏等^[11]提出的启发式代价函数优化了计算效率,但仍未能有效平衡路径平滑性和规划时间。

在局部路径规划中,人工势场法因其简单高效的实时避障特性被广泛应用^[12],可实时避开障碍物并生成平滑的轨迹,但传统人工势场法也存在局部最小值及目标不可达等缺陷^[13]。Abdalla等^[14]通过结合模糊逻辑和人工势场法,部分解决了局部最优问题,但路径易产生振荡且计算复杂度较高。Li等^[15]将混沌理论的搜索算法引入人工势场的势场函数中,通过改变势场中的系数,解决传统人工势场法的缺陷。

露天矿区具有显著的非结构化特点,其运输路

线往往受矿山作业需求、地形变化以及临时性道路改线的影响较大。如随着采掘面的延伸,装载点和卸载点的位置以及运输道路可能随时调整或废弃,导致场景具有显著的临时性与多变性^[16]。此外,矿区作业环境中的突发障碍物,如出现其他车辆、采矿设备或落石等,也对路径规划算法的实时性和避障能力提出了更高要求^[17]。由于矿区场景的规模和结构存在差异,固定参数配置的HA*算法难以适应所有场景,这可能导致规划路径不平滑甚至无法生成可行路径,从而影响规划的有效性和实际应用的可靠性。尤其在运输作业中,HA*算法缺乏实时重规划机制,难以满足避障需求,而在传统人工势场法的作用下可能会出现往复运动的现象,为减少车辆等待时间并提高整体作业效率,路径规划算法必须具备高效规划和实时响应的能力,以满足露天矿区的实际需求。

HA*算法和人工势场法在露天矿区场景中均面临各自的局限性,难以单独胜任路径规划任务。因此,如何结合全局路径规划的鲁棒性与局部路径优化的实时性,提出一种高效可靠的路径规划方法,成为亟待解决的问题。现有的HA*算法缺乏自适应机制,无法根据矿区环境变化自动调整关键参数,从而导致路径规划结果不稳定。为了解决这一问题,智能优化算法逐渐成为一种有效的解决方案。如粒子群算法和蚁群算法^[18-19],能够自适应地调整参数,从而提高路径规划的全局性能。然而,这些算法在处理复杂的高维参数空间时易陷入局部最优,而灰狼优化算法具有较强的全局搜索能力,能够在参数空间中找到最优解,同时在局部搜索时具备较高的精度^[20]。

基于上述分析,本文提出了一种基于灰狼优化的自适应混合A*和人工势场(grey wolf optimization-based adaptive hybrid A* and artificial potential field, GWO-HAPF)方法,该方法通过灰狼优化算法对HA*算法中的关键参数进行自适应调整,克服了HA*算法固定参数适用性不足的问题,能够更好地适应矿区场景的显著差异,确保路径的运动学约束得以满足,提高规划成功率,并优化了全局路径规划的整体质量。在局部规划中,改进了传统人工势

场算法, 引入逃出力机制和对斥力场的优化, 满足了露天矿区无人驾驶作业中的高效避障要求。最后实验结果验证了本文提出的方法在路径长度、平滑性、实时避障和路径规划效率方面的显著优势, 为露天矿区无人矿卡的高效运行提供了可靠的技术支撑。

1 无人矿卡路径规划方法

1.1 基于灰狼优化的自适应HA*全局路径规划

(1) HA*算法关键参数

本文采用两自由度车辆的运动学模型来计算无人矿卡的行驶过程, 车辆模型如图1所示, 其中 L_w 为车辆的轴距, L_f 为车辆前悬, L_r 为车辆后悬, L_b 为车辆宽度, (x, y) 、 φ 和 θ 分别代表车辆的位置、转向角和航向角。该模型以车辆后轴中心为基准点, 描述了车辆在行驶过程中的运动约束:

$$dx \sin(\theta) - dy \cos(\theta) = 0 \quad (1)$$

$$K = \frac{\tan \varphi}{L_w} \quad (2)$$

其中, K 为形式路径曲率。




图1 车辆模型

HA*算法结合车辆运动学模型和连续空间的搜索策略, 生成满足转向约束的可行路径。综合考虑方向切换、转向变化等因素构建节点代价函数^[8], 具体的代价函数表示为:

$$g(x) = \sum_{i=1}^k \left(L(i) + C_{\text{gear}} \cdot G(i) + C_{\text{back}} \cdot B(i) + C_{\text{change}} \cdot \Delta \varphi(i) + C_{\text{angle}} \cdot |\varphi(i)| \right) \quad (3)$$

其中, $L(i)$ 为路径长度, 表示车辆在第 i 步的移动距离; C_{gear} 为挡位切换的代价; $G(i)$ 表示车辆的运

行方向, 通常前进为 $G(i)=1$, 倒车为 $G(i)=-1$; C_{back} 为反向行驶代价; $B(i)$ 表示是否进行倒车操作; C_{change} 为转向变化的代价; $\Delta \varphi(i)$ 为转向角变化; C_{angle} 为转向角度代价; $\varphi(i)$ 为车辆当前转向角, 转向角过大可能导致急转, 难以跟踪控制。

启发式代价 $h(x)$ 用于估算当前节点到目标节点的代价, 通常采用欧氏距离进行估算。在HA*算法中, 启发式代价可以表示为:

$$h(x) = C_h \cdot d(i, \text{goal}) \quad (4)$$

其中, C_h 为启发式函数的权重, 调节启发式引导的强弱, 较高的值会更倾向于快速逼近目标位置, 而较低的值则可能产生更多的局部搜索; $d(i, \text{goal})$ 为当前节点 i 到目标节点之间的欧氏距离。

包含上述5个关键代价参数的 $p^* = (C_{\text{gear}}, C_{\text{back}}, C_{\text{change}}, C_{\text{angle}}, C_h)$ 对路径规划效果有显著影响, 然而传统HA*算法采用固定参数配置, 难以适应露天矿区环境中多变的作业场景和复杂需求, 导致规划路径不平滑, 甚至无法生成可行路径。

(2) 灰狼优化算法

灰狼优化算法以模拟灰狼群体的社会结构和捕猎行为为核心, 具有处理多目标优化问题的独特优势。灰狼群体的分层结构(α 狼、 β 狼、 δ 狼和 ω 狼)通过分级决策与协同搜索, 能够有效实现全局搜索与局部搜索的动态平衡^[20]。这种机制与露天矿区无人矿卡的路径规划中的多目标优化需求高度契合。每轮迭代中, 灰狼的个体位置更新如下:

$$D_\alpha = |C_1 X_\alpha - X(t)| \quad (5)$$

$$D_\beta = |C_2 X_\beta - X(t)| \quad (6)$$

$$D_\delta = |C_3 X_\delta - X(t)| \quad (7)$$

$$C_i = 2r_i, i = 1, 2, 3 \quad (8)$$

其中, $X(t)$ 为当前灰狼的位置向量, 包含各个待优化的参数值; D_α 、 D_β 和 D_δ 为 α 狼、 β 狼和 δ 狼与候选 ω 狼之间的距离; X_α 、 X_β 、 X_δ 分别为 α 狼、 β 狼、 δ 狼的位置; r_i 为取值范围为 $[0, 1]$ 的随机数向量; C_i 为系数向量, 用来调节灰狼个体与 α 狼、 β 狼、 δ 狼的距离, 根据式(5)~式(7)计算出新的位置, 更新如下:

$$X_1(t) = X_\alpha - A_1 D_\alpha \quad (9)$$

$$X_2(t) = X_\beta - A_2 D_\beta \quad (10)$$

$$X_3(t) = X_\delta - A_3 D_\delta \quad (11)$$

$$A_i = 2a(t)r_2 - a(t), i = 1, 2, 3 \quad (12)$$

$$a(t) = 2 \cdot \left(1 - \frac{t}{T}\right) \quad (13)$$

其中, A_i ($i=1,2,3$) 为控制灰狼移动幅度的向量, 表示灰狼靠近或远离猎物的程度, $a(t)$ 为随迭代次数逐步递减的系数, t 为当前迭代次数, T 为最大迭代次数, r_2 为取值范围为 $[0, 1]$ 的随机数向量。最终, 灰狼的更新位置为:

$$X(t+1) = \frac{X_1(t) + X_2(t) + X_3(t)}{3} \quad (14)$$

通过不断迭代, 灰狼群体会逐步逼近最优解。随着迭代次数的增加, 参数 $a(t)$ 会线性递减, 使灰狼的搜索范围逐渐收缩, 最终达到全局最优解。

(3) 参数自适应调整策略

在无人矿卡的路径规划中, 为满足矿区作业的实际需求, 路径规划需同时注重规划效率与路径质量。一方面, 应尽可能最小化路径长度, 以减少车辆的行驶时间和能耗, 提高运输效率; 另一方面, 路径的平滑度是影响行驶安全性和舒适性的重要因素, 较平滑的路径能够有效减少车辆运行中的颠簸和急剧变向, 保障行驶的稳定性。此外, 实时规划能力亦是关键指标, 需要确保路径规划在较短的时间内完成, 以满足矿区环境中的动态调度需求。基于以上要求, 可将路径长度、平滑度以及规划时间定义为优化目标, 构建目标函数以同时最小化上述指标, 并找到最优的路径参数 p^* , 其目标函数形式可表示为:

$$\min_p J(p^*) = \partial_1 L(p^*) + \partial_2 S(p^*) + \partial_3 T(p^*) \quad (15)$$

其中, p^* 为 HA* 算法中的一组待优化参数, ∂_1 、 ∂_2 、 ∂_3 分别为路径长度、平滑度和规划时间的权重系数, $L(p^*)$ 为路径长度, $S(p^*)$ 为路径的平滑度, 即连续路径之间的偏转角度变化, $T(p^*)$ 为规划时间, 可以通过路径节点的数量和步长估算, 分别表示如下:

$$L(p^*) = \sum_{i=1}^{N-1} \sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2} \quad (16)$$

$$S(p^*) = \sum_{i=1}^{N-1} |\theta_{i+1} - \theta_i| \quad (17)$$

$$T(p^*) = N \cdot \Delta t \quad (18)$$

其中, N 为路径节点数量, Δt 为探索步长。无人矿卡在露天矿区使用 HA* 算法进行路径规划时, 规划效果直接受一组参数 p^* 的影响。这些参数的设置应针对不同的场景和任务进行调整。固定的参数

配置无法适应露天矿山实际变化的环境。因此, 本文提出了灰狼优化-自适应混合 A* 调整策略, 能够根据不同的场景动态调整这些参数, 从而生成更加适合实际应用的路径。

自适应调整策略通过灰狼优化算法在搜索空间中形成一种自适应的包围机制, 对一组参数 p^* 进行动态搜索和更新, 这种机制能够根据优化过程的不同阶段自动调整搜索策略, 有效避免了局部最优解, 并且多目标优化中的各个目标将被综合考虑, 找到一个适用于实际场景的最优参数组合。综上所述, 实现流程描述如下。

步骤1 定义多目标函数: 建立由多目标函数驱动的参数自适应机制。

步骤2 初始化: 在参数空间内随机生成初始的灰狼群体, 每个灰狼的个体 $X_i(0)$ 是一组参数组合 p^* 。

步骤3 种群排序: 对于每个个体 $X_i(t)$, 计算所有目标函数的值, 并据此确定当前种群的 α 狼、 β 狼、 δ 狼和 ω 狼。

步骤4 位置更新: 根据式 (5) ~ 式 (7)、式 (9) ~ 式 (11)、式 (14) 以及 HA* 算法的结果进行位置更新。

步骤5 收敛判断: 若算法满足终止条件, 停止迭代并输出最优解 p^* ; 否则, 转步骤3。

这种自适应调整策略使 HA* 算法能够根据不同场景的需求自动优化参数配置, 避免了手动调整参数的复杂性, 并且能够保证无人矿卡在露天矿区环境下生成平滑、可行的最优路径, 实现了对路径规划参数的智能化调整, 从而提升了算法的效率和鲁棒性。

1.2 基于改进人工势场的局部路径规划

在实际矿区作业中, 无人矿卡的行驶路径可能受到突发障碍物的影响, 如落石、其他车辆或采矿设备等。这些障碍物未包含在全局路径规划的地图中, 可能导致规划路径中断或无法行驶。本文引入人工势场算法进行局部路径规划, 针对发生碰撞的路段进行重规划, 确保路径与障碍物保持安全距离, 到达预定目标。

人工势场法通过虚拟力场来引导无人矿卡避开障碍物并朝目标点行驶, 定义障碍物产生的斥力场为 U_{rep} 和目标点产生的引力场为 U_{att} , 根据引力和斥力势场产生的合力势场避开障碍物^[21]:

$$U_{\text{rep}} = \begin{cases} \frac{1}{2} K_{\text{rep}} \left(\frac{1}{d_{\text{obs}}} - \frac{1}{d_0} \right)^2, & d_{\text{obs}} \leq d_0 \\ 0, & d_{\text{obs}} > d_0 \end{cases} \quad (19)$$

$$U_{\text{att}} = \frac{1}{2} K_{\text{att}} (P - P_g)^2 \quad (20)$$

其中, K_{rep} 为斥力系数, d_{obs} 为无人矿卡与障碍物之间的距离, d_0 表示障碍物对车辆产生作用的最大影响范围, K_{att} 为引力系数, P 为当前矿卡位置, P_g 为目标点的位置。

人工势场作用下无人矿卡所受终点的引力为 F_{att} :

$$F_{\text{att}} = K_{\text{att}} (P_g - P) \quad (21)$$

为解决传统人工势场法的局部最小值问题, 本文引入逃出力机制。当车辆长时间停留在某点时, 判断其是否到达目标点, 如若没有, 由逃出力帮助无人矿卡逃出该点, 该力的大小随机赋值, 但方向与引力方向或斥力方向垂直, 以帮助车辆逃出局部最小值点。引出逃出力后路径规划流程如图2所示。




图2 引出逃出力后路径规划流程

在矿区突发障碍物的影响下, 传统人工势场法易出现目标不可达问题。本文对斥力进行了优化设计, 通过加入距离参数调整斥力, 距离参数是无人矿卡当前位置与障碍物之间的欧氏距离, 所受斥力 F_{req} 表达式为:

$$F_{\text{req}} = \begin{cases} k_{\text{rep}} \left(\frac{1}{d_{\text{obs}}} - \frac{1}{d_0} \right) \|P - P_{\text{obs}}\|^\gamma, & d_{\text{obs}} \leq d_0 \\ 0, & d_{\text{obs}} > d_0 \end{cases} \quad (22)$$

其中, P_{obs} 为障碍物位置, $\|P - P_{\text{obs}}\|$ 表示矿卡当前位置与障碍物位置的欧氏距离, γ 为障碍物的斥力

调节参数, 且 $\gamma > 0$ 。

1.3 方法整体流程

本文提出的 GWO-HAPF 方法以露天矿区无人矿卡的路径规划需求为背景, 通过全局路径规划与局部路径优化的结合, 实现了对矿山环境中路径规划问题的全面应对, 方法整体流程如图3所示。与现有路径规划方法相比, 本方法在处理矿区场景时展现了显著优势, 尤其在参数自适应调整、局部避障响应及路径平滑优化等方面实现了技术突破。

首先, 本文通过自适应 HA* 算法为车辆规划出从起点到终点的全局最优路径。为适应露天矿区环境中多样化的作业场景, 本文引入灰狼优化算法对 HA* 算法的一组关键参数 p^* 进行自适应调整。灰狼优化算法通过多目标优化机制, 动态调整参数配置, 克服了传统固定参数设置可能导致的路径规划质量不稳定问题, 成功实现了路径规划效率、路径平滑度与路径长度的多目标平衡。

然后, 在车辆行驶过程中, 针对矿区环境中突发性障碍物, 本文采用改进的人工势场法对局部路径进行优化。具体而言, 当局部障碍物阻碍全局路径时, 基于障碍物的斥力作用范围, 从全局路径中提取子路径段, 将区间末端节点设为局部目标点, 并以车辆当前位置为局部规划起点, 综合计算引力 and 斥力合力方向以调整路径。为解决传统人工势场法中的局部最小值问题和目标不可达问题, 本文引入了逃出力机制, 并优化了斥力函数。逃出力使车辆能够摆脱局部困境, 斥力优化则提升了避障能力和路径规划的可靠性。

最终, 通过全局路径规划与局部路径优化的协同工作, 本文方法能够在矿区环境中生成一条高效、安全且平滑的路径, 全面满足露天矿区无人矿卡路径规划的实际需求。

2 实验设计与结果分析

为了验证本文提出的方法在露天矿区场景下的有效性, 本文通过仿真实验对其性能进行了验证。实验使用的矿山场景数据来自 OnSite 平台中真实露天矿区的采样地图数据^[22]。实验设计充分考虑了矿区环境的场景多样性, 涵盖矿区环境的精确模拟、无人矿卡模型的构建、突发性障碍物设置和实时路径规划需求。实验结果采用多项关键指标进行评估, 包括路径长度、路径平滑性、避障成功次数以及运行时间, 以全面分析本文所提方法在矿区环




图3 方法整体流程

境中的路径规划性能与实际应用潜力。

2.1 实验设置

仿真实验使用 Python 语言实现，实验仿真环境为 PyCharm Community Edition 2021.3.3，通过读取 JSON 文件加载真实矿区场景数据。实验在配置为 2.0 GHz-4.5 GHz AMD Ryzen 5825U 处理器的计算机上执行，运行操作系统为 Windows 11，Python 版本为 3.9。本文实验场景基于露天矿区的典型作业场景构建，涵盖了装载区、卸载区、交叉路口等多个典型作业区域，并包括部分狭窄路段，要求无人矿卡在作业区域内进行路径规划和避障操作。为验证所提方法的有效性，本文采用文献[8]提出的 HA* 算法和文献[11]提出的改进混合 A*（improved hybrid A*，IHA*）算法作为对比项，IHA* 算法在传统 HA* 算法的基础上，优化了子节点拓展方式，并对启发式函数与代价函数进行了合理设计。实验相关参数见表 1，其中一组关键参数 p^* 的值域通过结合矿区实际优化需求和多次仿真实验的

结果进行调整得到^[20]，以确保实验的科学性和可行性。

表1 实验相关参数

参数	取值
L_F/m	4.2
L_W/m	5.6
L_R/m	3.6
L_B/m	6.7
$\Delta t/m$	0.4
车辆前轮最大转角 $\varphi_{\max}/rad$	0.6
C_{gear}	[50, 100]
C_{back}	[2, 50]
C_{change}	[2, 50]
C_{angle}	[2, 50]
C_h	[2, 10]
T	20
K_{rep}	0.53
d_0	30
K_{att}	10

2.2 结果分析

(1) 参数优化效果

本文针对泊入场景开展实验,通过设置多组起点和终点不同的工况,评估优化后的参数组合在不同路径规划条件下的性能表现。起终点的变化导致路径复杂度产生显著差异,灰狼优化算法能够根据每种具体情况对HA*算法的关键参数进行自适应调整,生成适应性最优路径。实验结果充分体现了GWO-HAPF方法在动态调整HA*算法参数以优化路径规划性能方面的有效性与优势,装载场景下不同起始位姿规划效果如图4所示,装载场景下规划指标对比见表2。


由表2的结果可知,在计算效率方面,HA*算法性能明显逊于IHA*算法和GWO-HAPF方法,其路径规划时间约为后两者的5倍以上。GWO-HAPF方法在4种不同位姿下的规划时间均提高了6%以上。在实际矿区作业中,较高的时间成本可能导致无人矿卡的等待时间增加,从而影响作业效率和进度。在路径质量方面,如图4(a)所示,当起始位姿为a时,GWO-HAPF方法规划出的路径与其他算法相比,不仅长度显著变短,而且更加平滑。在泊入目标位置阶段,GWO-HAPF方法避

表2 装载场景下规划指标对比


起始位姿	方法	规划时间/s	路径长度/m	平滑度
a	HA*	205.23	505.2	1.57
	IHA*	40.97	539.2	0.34
	GWO-HAPF	38.50	349.6	0.12
b	HA*	201.51	144.2	0.26
	IHA*	38.92	142.8	0.25
	GWO-HAPF	32.67	142.8	0.25
c	HA*	214.15	317.3	0.38
	IHA*	41.19	316.8	0.38
	GWO-HAPF	36.29	307.6	0.23
d	HA*	215.25	531.0	0.93
	IHA*	41.26	586.8	0.34
	GWO-HAPF	37.41	551.6	0.05

免了长距离倒车操作,路径长度比HA*算法减少了30.7%,比IHA*算法减少了35.1%。在平滑度上,GWO-HAPF方法比HA*算法提高了92.3%,比IHA*算法提高了64.7%。


如图4(b)所示,当起始位姿为b时,各方法规划的路径长度差异较小。这可能是由于在短距离路径规划中,参数调整对规划结果的影响相对有限。然而,该现象并不影响本文方法在其他典型场景中的表现优势。在露天矿区的大多数实际作业场




(a) 位姿a



(b) 位姿b



(c) 位姿c



(d) 位姿d

图4 装载场景下不同起始位姿规划效果

景中，区域通常具有较大的空间跨度或狭长的作业通道，本文提出的方法在这些更具代表性的场景中展现出了显著的改进效果。

如图4(c)所示，当起始位姿为c时，HA*算法和IHA*算法的路径长度有所增加，并且规划路径中全程倒车至指定位置的操作在矿区实际作业中并不符合要求。而GWO-HAPF方法通过更合理的路径规划显著改善了这一问题，其平滑度相较于其他两种方法提升了约39%。

如图4(d)所示，当起始位姿为d时，GWO-HAPF方法的路径长度略高于HA*算法，原因在于GWO-HAPF方法扩展节点较少，车辆倾向于先沿朝向方向直接行驶，导致路径长度略微增加，但仍比IHA*算法减少了5.9%。在长距离规划的位姿a和位姿d下，HA*算法规划的路径中频繁的方向调整导致路径出现明显的抖动现象；而IHA*算法虽有所改进，但其规划路径中仍存在一些不必要的弧线运动，增加了无人矿卡的控制难度。

通过同一场景下不同位姿的实验结果可以看出，灰狼优化算法进行自适应参数规划的重要性，GWO-HAPF方法能够根据不同的起终点灵活调整HA*算法的关键参数，从而生成更优越的路径规划方案。优化后的路径较为平滑，倒车频率得到了显著降低，规划时间也保持在合理范围内。这表明关键参数的优化影响了路径规划的效率与质量。

(2) 不同场景下全局路径规划性能

为了验证提出方法的鲁棒性，本文在多种不同的矿区作业场景进行了多次重复实验，不同场景下规划效果如图5所示，不同场景下规划指标对比实验结果见表3。由表3可知，HA*算法所需时间与其他两种方法的5倍左右。图5(a)所示卸载场景相较于装载场景，该场景中的障碍物分布较少，地图结构相对简单。相比之下，本文提出的方法在规划时间上比IHA*算法提升了34.9%，路径长度比HA*算法减少了11.6%。尽管与IHA*算法在路径长度上的差异不大，但本文方法在路径平滑性方面表现更优，相较于HA*算法提升了56.3%，比IHA*算法提升了16.0%，有效减少了不必要的方向调整。

图5(b)展示了矿区道路中的窄弯场景，由于道路弯曲度较大且可搜索空间受限，该场景下无人矿卡的行驶安全性和路径规划难度显著增加。在此场景中，HA*算法由于搜索空间限制未能生成可行路径，表现出在复杂场景中的适应性不足；相比

之下，IHA*算法虽能够生成可行路径，但其规划的路径平滑性较差。本文提出的方法在路径平滑性上提升了85.5%，且规划时间比GWO-HAPF方法高出22.6%。

图5(c)展示了无人矿卡绕开路口障碍物并准确进入指定道路的场景。在此场景中，HA*算法生成的路径不具备实际行驶能力，而本文提出的方法在路径长度、平滑性和计算效率3项指标上均优于HA*算法和IHA*算法。具体而言，GWO-HAPF方法的规划时间比IHA*算法提升了9.3%，路径长度比HA*算法减少了23.1%，比IHA*算法减少了2.5%；路径平滑度比HA*算法提升了89.6%，比IHA*算法提升了50.0%。

图5(d)展示了露天矿区中典型的狭窄区域场景。相比开阔地带，该场景更加局限，无人矿卡应尽可能远离障碍物以确保安全抵达目标位姿。本文提出的方法与HA*算法均避免了长距离倒车操作，但HA*算法规划出的路径存在明显的抖动现象，并且部分路径过于贴近障碍物，增加了潜在风险。而本文方法在安全性和路径平滑性上表现更优。具体而言，本文方法的规划时间比IHA*算法提升了10.8%，路径长度比IHA*算法减少了4%，路径平滑度比HA%算法提升了82.8%，比IHA*算法提升了33.3%。

表3 不同场景下规划指标对比实验结果

场景	方法	规划时间/s	路径长度/m	平滑度
1	HA*	32.84	250.4	0.48
	IHA*	7.89	224.4	0.25
	GWO-HAPF	5.13	221.2	0.21
2	HA*	—	—	—
	IHA*	38.65	410.4	0.83
	GWO-HAPF	29.89	409.9	0.12
3	HA*	197.72	342.3	1.35
	IHA*	44.21	270.0	0.14
	GWO-HAPF	40.12	263.2	0.07
4	HA*	221.43	500.1	1.75
	IHA*	47.73	525.6	0.30
	GWO-HAPF	42.56	502.0	0.25

总体来说，在不同场景下本文方法生成的全局路径不仅能够有效满足露天矿区作业中对车辆运动学约束的要求，还在路径平滑性、路径长度和规划效率上具有显著优势，为露天矿区场景下的无人驾驶提供了高效可靠的解决方案。




图5 不同场景下规划效果

(3) 局部路径重规划

在已知矿区作业区域地图的情况下,通过自适应HA*算法可以从起点到终点生成一条全局路径。然而,在实际作业过程中,规划好的全局路径可能会受到突发障碍物的影响,使无人矿卡无法按照既定路径继续行驶。这种情况下,局部路径重规划尤为重要,本文通过改进后的人工势场法实现实时避障,并在完成避障后回归全局路径继续行驶,确保矿卡在行驶中的安全性和高效性。为模拟实际场景中的突发障碍物,验证GWO-HAPF方法的可行性,实验中随机引入障碍物,利用传统人工势场法、IHA*算法分别进行100次实验。局部路径规

划效果如图6所示,局部避障指标对比见表4。

由图6可知,传统人工势场法在规划中陷入局部最小值时,路径末端出现路径来回运动堆叠而成的小色块,导致无法到达目标点,因此未计入表4的数据中;IHA*算法在对第二个障碍物进行避障时,路径出现了折点;而本文方法进行局部规划出的路径相对更加平滑,有利于后续的无人矿卡控制和路径跟踪。由表4实验数据可知,GWO-HAPF方法重规划时间比IHA*算法减少了95.8%,路径平滑度提高了89.8%,并且避障成功率高。GWO-HAPF方法能够在较短时间内生成平滑且可行的避障路径,同时在路径平滑度和规划效率方面均优于

传统人工势场法和IHA*算法,验证了本文方法的有效性。




图6 局部路径规划效果

表4 局部避障指标对比

方法	重规划时间/s	规划成功次数	路径平滑度
IHA*	38.16	93	1.08
GWO-HAPF	1.62	98	0.11

3 结束语

本文针对露天矿区无人矿卡路径规划的实际需求,提出了GWO-HAPF方法,通过在全局路径规划中引入灰狼优化算法,实现了HA*算法关键参数的自适应调整,从而生成更优化的路径。同时,本文在局部路径规划中,引入了改进的人工势场

法,通过优化斥力函数和增加出逃力,有效提升了局部避障性能和路径的平滑性。

实验结果表明,在当前实验设备的算力条件下,GWO-HAPF方法在多个矿区作业场景下均表现出显著的优势。具体而言,与HA*算法和IHA*算法相比,GWO-HAPF方法在计算效率、路径长度和路径平滑性方面均有显著提升。在计算效率方面,GWO-HAPF方法的路径规划时间相较于HA*算法减少了80%左右,相较于IHA*算法减少了6%~34%。在路径长度方面,GWO-HAPF方法在部分场景和位姿下路径长度比HA*算法平均减少了17.1%,比IHA*算法平均减少了9.8%;在其他场景和位姿中,路径长度与对比算法相当,表现稳定。在路径平滑性方面,GWO-HAPF方法较HA*算法平均提升了75.7%,较IHA*算法平均提升了53.4%,有效减少了不必要的方向调整。此外,在面对突发障碍物的局部路径重规划实验中,GWO-HAPF方法的重规划时间相较于IHA*减少了95.8%,路径平滑度提高了10.19%,并且避障成功率更高,确保了局部规划的实时性和稳定性。

综上所述,本文提出的GWO-HAPF方法不仅在全局路径规划上实现了路径规划质量的优化,还在局部路径规划中有效提升了路径平滑性和实时性,为解决露天矿区中无人矿卡路径规划问题提供了具有实际应用价值的技术方案。后续研究将重点探讨动态障碍物的处理,尤其是移动障碍物和未知障碍物的应对策略,以提升算法的实时避障能力。同时,考虑矿区环境中的极端天气和复杂地形,笔者将进一步提升算法的鲁棒性和适应性,以持续提升露天矿区环境下的鲁棒性与作业连续性。

参考文献:

- [1] 阮顺领,赵微,辛智,等.改进时间弹性带的露天矿无人卡车避障路径规划研究[J].智能系统学报,2024,19(6):1449-1457.
RUAN S L, ZHAO W, XIN Z, et al. Research on the obstacle avoidance path planning of unmanned truck in open-pit mine with improved time-elastic-bands[J]. CAAI Transactions on Intelligent Systems, 2024, 19(6): 1449-1457.
- [2] 丁志杰,王亚飞,章翼辰,等.基于复合动态采样的自动驾驶矿车节能路径规划方法[J].汽车工程,2024,46(4):588-595,642.
DING Z J, WANG Y F, ZHANG Y C, et al. Energy-saving planning method for autonomous driving mining trucks based on composite dynamic sampling[J]. Automotive Engineering, 2024, 46(4): 588-595, 642.
- [3] BELLAMY D, PRAVICA L. Assessing the impact of driverless haul trucks in Australian surface mining[J]. Resources Policy, 2011, 36(2): 149-158.

- [4] LIMA P F, NILSSON M, TRINCAVELLI M, et al. Spatial model predictive control for smooth and accurate steering of an autonomous truck[J]. IEEE Transactions on Intelligent Vehicles, 2017, 2(4): 238-250.
- [5] LI H, LI Y M, CHEN P, et al. A secure trajectory planning method for connected autonomous vehicles at mining site[J]. Symmetry, 2023, 15(11): 1973.
- [6] YI B L, BENDER P, BONARENS F, et al. Model predictive trajectory planning for automated driving[J]. IEEE Transactions on Intelligent Vehicles, 2019, 4(1): 24-38.
- [7] 唐炜, 谭啸, 孙宇, 等. 基于A*与动态窗口法的物料传输平台路径规划研究[J]. 智能科学与技术学报, 2023, 5(4): 515-524.
TANG W, TAN X, SUN Y, et al. Research on path planning of material transmission platform based on A* and dynamic window method[J]. Chinese Journal of Intelligent Science and Technology, 2023, 5(4): 515-524.
- [8] DOLGOV D, THRUN S, MONTEMERLO M, et al. Path planning for autonomous vehicles in unknown semi-structured environments[J]. The International Journal of Robotics Research, 2010, 29(5): 485-501.
- [9] 邓穆坤, 刘勇, 黄佳德, 等. 基于混合A*算法的无人驾驶矿用卡车路径优化研究[J]. 控制与信息技术, 2022(5): 60-67.
DENG M K, LIU Y, HUANG J D, et al. Research on hybrid A*Based path optimization of unmanned mine truck[J]. Control and Information Technology, 2022(5): 60-67.
- [10] TU K B, YANG S S, ZHANG H, et al. Hybrid A based motion planning for autonomous vehicles in unstructured environment[C]//Proceedings of the 2019 IEEE International Symposium on Circuits and Systems (ISCAS). Piscataway: IEEE Press, 2019: 1-4.
- [11] 陈鑫鹏, 徐彪, 胡满江, 等. 一种基于等步长分层拓展的混合A*路径规划方法[J]. 控制与信息技术, 2021(1): 17-22, 29.
CHEN X P, XU B, HU M J, et al. A hybrid-A* path planning method based on equal step hierarchical expansion[J]. Control and Information Technology, 2021(1): 17-22, 29.
- [12] 韩伟. 室外环境基于多传感器履带式机器人自主导航[D]. 大连: 大连理工大学, 2017.
HAN W. Autonomous navigation of multi-sensor based crawler robot in outdoor environment[D]. Dalian: Dalian University of Technology, 2017.
- [13] ZHAI L, LIU C, ZHANG X Y, et al. Local trajectory planning for obstacle avoidance of unmanned tracked vehicles based on artificial potential field method[J]. IEEE Access, 2024, 12: 19665-19681.
- [14] ABDALLA T Y, ABED A A, AHMED A A. Mobile robot navigation using PSO-optimized fuzzy artificial potential field with fuzzy control[J]. Journal of Intelligent & Fuzzy Systems, 2016, 32(6): 3893-3908.
- [15] LI W H. An improved artificial potential field method based on chaos theory for UAV route planning[C]//Proceedings of the 2019 34rd Youth Academic Annual Conference of Chinese Association of Automation (YAC). Piscataway: IEEE Press, 2019: 47-51.
- [16] 唐龙. 露天矿矿山采场道路的修筑和养护[J]. 中国设备工程, 2020(23): 217-219.
TANG L. Construction and maintenance of stope roads in open pit mines[J]. China Plant Engineering, 2020(23): 217-219.
- [17] WANG X W, LI H R, HU M J, et al. HD map construction and update system for autonomous driving in open-pit mines[J]. IEEE Systems Journal, 2023, 17(4): 6202-6213.
- [18] BO L, ZHANG Z H, LIU Y, et al. Research on path planning method of solid backfilling and pushing mechanism based on adaptive genetic particle swarm optimization[J]. Mathematics, 2024, 12(3): 479.
- [19] ZHANG D, YIN Y B, LUO R, et al. Hybrid IACO-A*-PSO optimization algorithm for solving multiobjective path planning problem of mobile robot in radioactive environment[J]. Progress in Nuclear Energy, 2023, 159: 104651.
- [20] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61.
- [21] KHATIB O. Real-time obstacle avoidance for manipulators and mobile robots[J]. The International Journal of Robotics Research, 1986, 5(1): 90-98.
- [22] 王之中, 田野, 孙剑, 等. 自动驾驶测试公共服务平台建设与思考[J]. 交通运输工程学报, 2023, 23(6): 1-9.
WANG Z Z, TIAN Y, SUN J, et al. Construction and rethinking on public service platform for autonomous driving test[J]. Journal of Traffic and Transportation Engineering, 2023, 23(6): 1-9.

[作者简介]



韩彦岭 (1975-), 女, 博士, 上海海洋大学信息学院教授, 主要研究方向为路径规划算法、基于深度学习的图像分类与识别。



吕金科 (1999-), 男, 上海海洋大学信息学院硕士生, 主要研究方向为路径规划算法、智能优化。



周国峰 (1985-), 男, 博士, 上海海洋大学工程学院讲师, 主要研究方向为车辆动力学、建模、仿真和控制。



张力珂 (2001-), 男, 上海海洋大学信息学院硕士生, 主要研究方向为路径规划算法。



张云 (1974-), 男, 博士, 上海海洋大学信息学院教授, 主要研究方向为导航系统的高精度定位原理、导航系统反射信号的海洋遥感技术。