

DOI: 10.13382/j.jemi.B2508375

面向复杂曲面视觉检测的覆盖路径规划*

禾家辉 金晶

(哈尔滨工业大学航天学院 哈尔滨 150000)

摘要:针对汽车方向盘等具有复杂曲面的工件在自动化视觉检测中的路径规划需求,传统“先视点后路径”的解耦规划方法易陷入局部最优,难以兼顾覆盖率与效率。为此,提出一种视点与路径协同优化的覆盖路径规划方法。首先,基于目标点云模型的轴对齐包围盒进行空间细分,并结合随机偏移生成视点位置;通过球坐标系采样确定视点位姿,构建冗余视点集合。其次,建立融合景深、视场角、可见性及遮挡约束的视锥体覆盖评估模型,量化各视点的有效覆盖能力。最后,提出改进的混合灰狼优化算法-鲸鱼优化算法(IGWO-WOA),融合混沌映射初始化、反向学习策略、动态收敛因子及鲸鱼优化算法中的螺旋狩猎机制,实现视点选择与访问顺序的多目标组合优化。实验结果表明,在两种复杂方向盘模型上,所提方法相较传统的群智能算法,路径长度分别缩短 20.6% 与 11.5%,覆盖率提升至 99.7% 与 99.86%,全程实现零碰撞,路径质量显著优于对比方法。

关键词: 复杂曲面视觉检测;覆盖路径规划;多目标优化;IGWO-WOA;视点规划

中图分类号: TP242.6 **文献标识码:** A **国家标准学科分类代码:** 510.80

Coverage path planning for visual inspection of complex curved surfaces

He Jiahui Jin Jing

(School of Astronautics, Harbin Institute of Technology, Harbin 150000, China)

Abstract: To address the path planning requirements for automated visual inspection of workpieces with complex surfaces—such as automotive steering wheels—conventional decoupled approaches that first select viewpoints and subsequently plan paths are prone to local optima and struggle to simultaneously achieve high coverage and computational efficiency. To overcome this limitation, a coverage path planning method featuring joint optimization of viewpoints and trajectories is proposed. First, the axis-aligned bounding box of the target point cloud model is spatially subdivided, and candidate viewpoint positions are generated by applying random offsets to the centroids of the resulting subregions. Viewpoint orientations are then determined through sampling in spherical coordinates, yielding a redundant set of candidate viewpoints. Second, a frustum-based coverage evaluation model is established, incorporating constraints on depth of field, field of view, surface visibility, and self-occlusion to quantitatively assess the effective coverage capability of each candidate viewpoint. Finally, an enhanced hybrid grey wolf optimizer-whale optimization algorithm (IGWO-WOA) is introduced, integrating chaotic map-based initialization, opposition-based learning, a dynamic convergence factor, and the spiral hunting mechanism from the whale optimization algorithm to enable multi-objective co-optimization of viewpoint selection and visiting sequence. Experimental results on two complex steering wheel models demonstrate that, compared with conventional swarm intelligence algorithms, the proposed method reduces path length by 20.6% and 11.5%, achieves coverage rates of 99.7% and 99.86%, respectively, and ensures collision-free execution throughout the inspection process, thereby delivering significantly superior trajectory quality.

Keywords: visual inspection of complex surfaces; coverage path planning; multi-objective optimization; IGWO-WOA; viewpoint planning

0 引言

当前,制造业正加速向自动化与智能化转型^[1-2]。在此背景下,基于视觉的复杂曲面工件质量的自动化检测愈发关键,它不仅影响产品质量,还直接关系到生产流程的效率与稳定性。为了实现高质量检测,必须精心设计一条高度可行性的扫描路径。该路径需精准覆盖一系列具有特定空间定位和功能属性的路径点,确保视觉传感器(如工业相机或三维扫描仪)能够从合适的位置和视角获取完整、清晰的表面信息。机器人通过精确的运动控制与可靠的技术导航系统,依循预设路径移动,从而对工件进行全面、无遗漏、高精度的视觉数据采集,为后续的质量评估提供坚实基础。覆盖路径规划(coverage path planning, CPP)^[3]是机器人执行视觉检测任务首先要解决的核心问题,其目标是通过规划机器人的移动轨迹,高效覆盖给定区域或其关键部分。CPP技术广泛应用于大型结构三维重建^[4]、精准农业^[5]、船体水下检测^[6]以及复杂曲面的视觉检测^[7]等领域。当前, CPP主要分为两种,基于模型的方法^[8]和非基于模型的方法^[9],分别适用于不同应用场景,并针对具体需求提供相应的解决方案。

在复杂曲面的视觉检测领域,主流方法通常采用基于模型的策略:首先生成一组冗余视点(即视点采样),随后在该集合上进行覆盖路径规划。视点采样是确保机器人高效、准确完成视觉检测的关键步骤,其结果直接决定了视觉传感器在空间中的位置与观测方向,进而影响后续路径规划的有效性与检测质量。现有视点采样方法主要包括空间采样^[10]、顶点采样^[8]和补丁采样^[11]3种方式。Jing^[10]通过对目标物体两次体素扩张确定采样空间并随机生成候选视点,再用概率势场法确定视点方向。Scott^[8]则为模型表面网格顶点创建候选视点,对高分辨率复杂离散模型先进行曲率敏感重采样以创建最终视点候选集。Mosbach等^[11]依据物体几何特征对不同密度表面采样,随后利用B样条曲面重建对象,并将视点设于重建曲面的中心处,方向取其法线指向曲面。以上方法各有优劣,理想的视点应当兼顾视觉覆盖质量与空间分布多样性。

复杂曲面的视觉检测规划问题通常被划分为两个核心任务,视点规划(viewpoint planning problem, VPP)和路径规划。VPP任务旨在从采样得到的冗余视点集合中,通过优化过程筛选出一组满足特定标准的最优视点子集;而路径规划任务则负责确定这些视点的最佳访问顺序,并规划其间无碰撞的连接路径。本质上,路径规划可归结为旅行商问题(travelling salesman problem, TSP),即寻找一条最短路径,恰好访问每个选定视点一次。现有研究多采用解耦策略,先独立求解VPP,再基于所得

视点集求解TSP。刘洪鹏等^[12]采用贪心算法得到优选视点集后,利用模拟退火算法规划连接所有视点的最短路径,以实现模型表面全部图元的视觉覆盖。Phung等^[13]使用分层解耦方法计算每对视点间的最短无障碍路径,并通过增强的离散粒子群优化算法求解全局最短路径。同时借助GPU并行计算提升实时性。Cao等^[14]提出一种分层框架,在两个层级上协同处理采样视点的TSP问题。Mohammadikaji等^[15]将粒子群优化算法集成到贪心策略,实现候选视点的全局优化。Bircher等^[16]则采用交替两步优化范式,在每次迭代中同步优化视点选择与连接成本。

然而,视点规划与路径规划实际上是两个相互耦合的优化问题,若仅单独优化,往往难以兼顾视觉覆盖率与检测时间成本。近年来,研究者们开始探索联合优化策略。Jing等^[17]将视点规划和路径规划合并简为一个单目标优化问题,同步求解最优视点与最优路径,显著提升了检测效率。在此基础上,陈雨等^[18]考虑了无人机巡检任务的覆盖率约束,将路径长度、视点数目以及急转弯次数,加权转换为检测任务的总能耗作为优化目标,该方法引入更多实际约束,但也可能因权重设置导致某些目标被过度强化而牺牲其他性能。

针对上述挑战,面向复杂曲面工件的视觉检测任务,提出了一种基于目标曲面点云模型的覆盖路径规划方法。该方法引入一种改进的混合灰狼优化算法-鲸鱼优化算法(IGWO-WOA),将采样后的冗余视点集合纳入统一框架,对视点选择及其访问顺序进行多目标组合优化。突破传统独立视点规划与路径规划局限,充分考虑二者耦合关系,在保证高视觉覆盖率同时,显著缩短检测路径长度,提升整体检测效率与鲁棒性。

本文提出了一种面向复杂曲面视觉检测的最优覆盖视点生成方法,该方法基于目标曲面点云模型,通过包围盒细分结合随机偏移策略确定视点的空间位置,并采用球坐标系进行方向采样以构建完整视点位姿,位置与位姿共同构成初始冗余视点集合,为后续视觉检测奠基。构建一种融合多约束条件的视锥体覆盖评估模型,综合考虑景深范围、视场角限制、表面可见性和自遮挡等因素,对候选视点的有效覆盖能力进行量化评估。该模型为后续优化过程提供了可靠的评价依据,从而增强整个检测方案的全面性与可靠性。提出一种基于IGWO-WOA的多目标组合优化方法,突破传统“先选视点后规划路径”的解耦范式,在统一框架下同步优化视觉覆盖率、路径长度与运动安全性(即无碰撞约束)。该方法实现视点规划与路径规划的联合决策,最终生成一条兼顾检测全面性、路径高效性与操作安全性的扫描路径,为复杂曲面的自动化视觉检测提供了一种高效的解决方案。

1 方法概述

如图 1 所示,该方法以目标工件的点云模型为输入,执行步骤如下:1)通过最优覆盖视点采样生成初始冗余

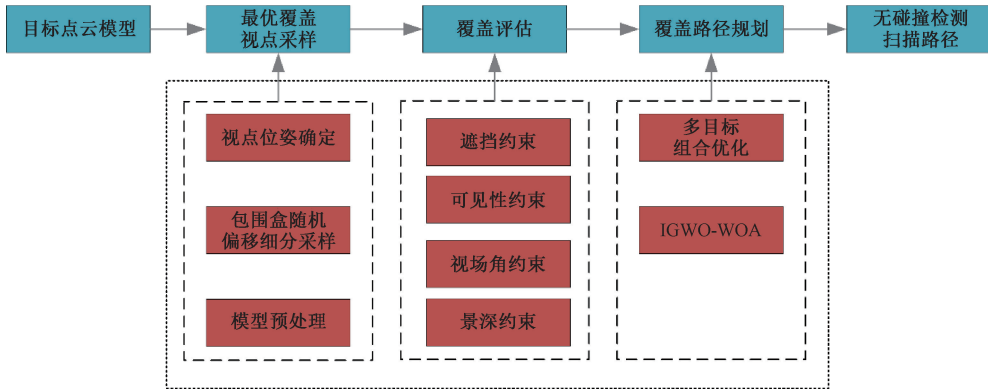


图 1 本文主要研究思路

Fig. 1 The main research ideas of this paper

2 最优覆盖视点采样

视点采样过程是获得一组全覆盖目标曲面的冗余视点集合,视点包含视觉传感器的位置和位姿信息,在检测中,通常将位姿表述为视觉传感器指向待检测曲面的方向。

2.1 模型预处理

点云模型可以通过激光雷达、深度相机等多种传感器获取,但是此类方法得到的点云模型不可避免地存在噪声、冗余点等,在实际研究过程中,需要对点云模型进行一系列预处理^[19],得到符合研究条件的点云模型。

1)对点云模型进行滤波降噪处理,去除噪声、离群点等。

2)进行体素下采样,减少点云数量,减少后续计算量。

3)对点云模型进行旋转、平移,使得其轴对齐包围盒平行于三维坐标轴,便于后续视点生成。

在预处理后,建立一个以点云轴对齐包围盒(axis-aligned bounding box, AABB)中心为原点,水平向右为 x 轴正向、竖直向上为 y 轴正向、向外为 z 轴正向的世界坐标系。

2.2 包围盒随机偏移细分采样

在处理点云数据时,构建 AABB 是关键步骤。首先,通过精确计算点云在 x, y, z 3 个坐标轴上的最小值 $x_{\min}, y_{\min}, z_{\min}$ 与最大值 $x_{\max}, y_{\max}, z_{\max}$, 确定 AABB 的范围,其 3 条边长 L_x, L_y, L_z 分别为对应坐标值的差。为了在 AABB

视点集;2)基于视锥体覆盖评估模型,对各视点的有效性进行量化筛选;3)采用 IGWO-WOA 对冗余视点集及视点间访问顺序进行多目标组合优化,最终输出一条兼顾高覆盖率、短路径长度与无碰撞约束的扫描路径。

表面生成均匀分布的视点,对其 6 个平面进行均匀网格细分。以 $x=x_{\min}$ 为例详细说明细分及采样点过程,将该平面在 y 和 z 方向上分别等分为 k 个区间,对于第 i 行和第 j 列的细分网格,通过式(1)计算中心位置坐标。

$$\begin{cases} x_{center} = x_{\min} \\ y_{center} = y_{\min} + (i + 0.5) \frac{L_y}{k} \\ z_{center} = z_{\min} + (j + 0.5) \frac{L_z}{k} \end{cases} \quad (1)$$

随后,对细分后网格中心位置沿平面外法线方向进行随机偏移处理。向外偏移方向的单位向量为 \vec{n} ,偏移距离设为 Δx ,则经过偏移后的采样点坐标 (x_s, y_s, z_s) 可如式(2)所示。经此操作,获取仅包含位置信息的视点集合 $V(s)$,该数组唯一确定了视点在三维空间中的位置坐标。

$$\begin{cases} x_s \\ y_s \\ z_s \end{cases} = \begin{bmatrix} x_{center} \\ y_{center} \\ z_{center} \end{bmatrix} + \Delta x \cdot \vec{n} \quad (2)$$

2.3 视点位姿确定

针对视点集合 $V(s)$ 中仅包含位置信息的视点,利用球坐标系,以特定采样间隔角度 α 进行采样,获取多组极角 θ 和方位角 φ 的组合 $V_i(\theta, \varphi)$ 。通过式(3)将其转换为直角坐标,得到视线的方向向量坐标 (n_x, n_y, n_z) ,此时视点信息可完整表示为 $[x_s, y_s, z_s, n_x, n_y, n_z]^T$ 。借助旋转矩阵,将目标曲面点云模型坐标从世界坐标系转换至视点坐标系。将每个视点位置与对应覆盖率最大的视线方向进行组合,最终形成完整的候选视点集 $V(s)$ 。

$$\begin{cases} x = \sin\theta \cdot \cos\varphi \\ y = \sin\theta \cdot \sin\varphi \\ z = \cos\theta \end{cases} \quad (3)$$

3 覆盖评估模型

在生成候选视点集后,依据传感器成像约束条件,对目标模型点云与候选视点间的可见性展开分析,构建视锥体模型并判断当前视点下的可见点云,以此对各视点进行覆盖评估。评估过程主要涉及景深、视场角、可见性和遮挡4方面的约束条件。

1) 景深约束

景深是指相机聚焦时,在聚焦平面前后能获得清晰图像的距离区间,其范围受物距、镜头焦距、镜头光圈值等参数影响。基于景深原理,需在前后景深范围内确定合适的拍摄距离,确保点云坐标在视点坐标系下沿相机光轴方向投影的距离,处于相机视锥体的远近平面之间。

2) 视场角约束

视场角是相机在传感器尺寸和焦距作用下的最大观察范围,单相机视场区域呈四棱锥形,包含水平视场角和竖直视场角。点云坐标应位于深度视锥体半宽范围内,以满足视场角约束。

3) 可见性约束

对于点云模型中的点,其可见性由该点法向量与视点视线方向向量的夹角决定。当夹角 $\geq 90^\circ$ 时,点云可见。

4) 遮挡约束

采用射线追踪算法^[20],从视点向目标点云发射虚拟射线,若射线在抵达目标点云前与工件其他点云相交,则判定该点云被遮挡;仅当路径无阻挡时,目标点云才满足遮挡约束。

记视点为 v_i ,视点方向向量为 s ,根据视点位姿透视原理建立视锥体模型并根据约束条件判断点是否在视锥体内。

对于点云模型中任一点 A ,将其在世界坐标系下坐标记为 $X_w = (x_w, y_w, z_w)$,同样的法向量 n ,其在视点坐标系下的坐标 $X_s = (x_s, y_s, z_s)$ 如式(4)所示。

$$X_A = QX_w + X_s \quad (4)$$

式中: Q 为旋转矩阵; X_s 为该视点在世界坐标系下的坐标。

则点 A 在视锥体内需满足以下条件:

$$\begin{cases} -w_h \leq x_a \leq w_h \\ -w_v \leq y_a \leq w_v \\ d_1 \leq z_a \leq d_2 \\ \vec{n} \cdot \vec{s} < 0 \end{cases} \quad (5)$$

式中: w_h 为水平方向深度半宽(式(6)); w_v 为竖直方向深度半宽(式(7)); d_1 为近平面距离; d_2 为远平面距离。

$$w_h = (1 - h) \cdot w_{near_h} + r \cdot w_{far_h} \quad (6)$$

$$w_v = (1 - r) \cdot w_{near_v} + r \cdot w_{far_v} \quad (7)$$

式中: r 为深度比例(式(8)); w_{near_h} 为水平近平面半宽; w_{far_h} 为水平远平面半宽; w_{near_v} 为竖直近平面半宽; w_{far_v} 为竖直远平面半宽。

$$r = \frac{z_a - d_1}{d_2 - d_1} \quad (8)$$

在不同视点位置的多个方向向量处分别建立视锥体模型并依据式(5)进行覆盖评估,则视点 v_i 在方向向量 s_j 下的覆盖率 C 可表示为:

$$C = \frac{n_{cov}}{n_{all}} \times 100\% \quad (9)$$

式中: n_{cov} 为视锥体内的点的数量; n_{all} 为点云模型点的总数。

在不同视点位置的多个方向向量处建立视锥体模型并评估后,选取每个视点位置处覆盖率最大的方向向量作为当前视点的位姿,并通过视锥体剔除提取表面可见点云。如图2所示,箭头表示视点,线条四棱锥表示视锥体,绿色的点表示模型中已被覆盖的点,黑色的点表示未被覆盖到的点。

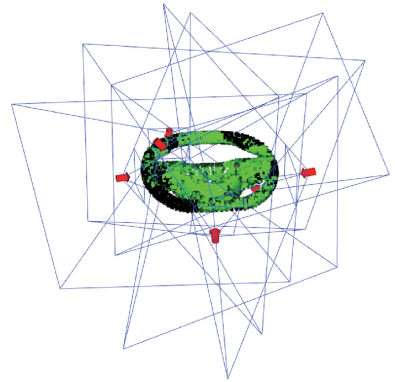


图2 视锥体剔除示意图

Fig. 2 Schematic diagram of frustum culling

在对视点完成覆盖评估后形成候选视点集合 $V(s)$,编码候选视点与点云模型中的点的可见性信息,并将其储存在图3所示的二维可见性矩阵 M 中,矩阵的行数 m 表示视点的个数,列数 n 表示点云模型中点的数量,为了方便查询视点对点的可见性信息,将矩阵 M 设置为二进制矩阵,即当点 P_j 对视点 v_i 可见时,将矩阵 M 中对应的元素 M_{ij} 为1,否则将其设置为0。

4 覆盖路径规划

在得到冗余视点集合后,通过 IGWO-WOA 进行多目




图 3 可见性矩阵示意图

Fig. 3 Diagram of visibility matrix

标组合优化,充分考虑视点规划和路径规划之间的耦合关系,在保证高覆盖率的同时有效缩减检测路径长度,获得全局最优的有序视点集合。

4.1 目标函数

目标函数主要考虑路径长度、碰撞规避以及覆盖惩罚 3 方面。其中,路径长度相关项用于衡量扫描路径总长度,综合相邻视点间距离与视点数量,其值越小检测效率越高,可有效削减检测时间与成本。碰撞规避项依据扫描路径与点云 AABB 相交状况进行计算,一旦发生相交便施加惩罚,相交越严重惩罚越重,以此规避碰撞路径,保障检测安全与准确;覆盖惩罚项则根据扫描路径视点集合对整个点云的覆盖程度确定,当覆盖率未达 100% 时产生惩罚,且覆盖率越低惩罚越显著,从而推动算法优先寻求全覆盖路径。基于此,构建优化目标函数如下:

$$F = \left[\sum_{i=1}^{n-1} d(v_i, v_{i+1}) + 0.5n \right] + (1000N_c) + [1000 \times (e^{5 \times (1-\gamma)} - 1)] \quad (10)$$

式中: \$n\$ 是扫描路径经过的视点个数; \$v_i\$ 表示路径中第 \$i\$ 个视点的位置; \$d(v_i, v_{i+1})\$ 表示第 \$i\$ 个视点和第 \$i+1\$ 个视点之间的欧氏距离; \$N_c\$ 表示扫描路径中与点云 AABB 相交的线段数量; \$\gamma\$ 表示扫描路径对应的视点集合对整个点云的覆盖率。

目标函数各组成部分的权重设计不仅基于实际检测任务的优先级,也充分考虑了各项的物理量纲与数值尺度差异。路径长度项以 \$m\$ 为单位,典型值在 \$10^1\$ 量级;碰撞次数 \$N_c\$ 为非负整数,通常取值为 0 或较小正整数;而覆盖率 \$\gamma\$ 为无量纲比值,其偏差 \$(1-\gamma)\$ 通常在 \$10^{-3} \sim 10^{-1}\$ 量级。若直接将 3 项相加,路径长度项将在数值上占据绝对主导,导致优化过程忽略覆盖与安全约束。为实现有效多目标平衡,通过预实验确定了如下权重配置:路径长度项系数设为 1;碰撞惩罚项和覆盖惩罚项的系数均设为 1000。该设置一方面通过量级对齐(将微小的覆盖率偏差和稀疏的碰撞事件放大至与路径长度相当的数值范围),确保 3 项在目标函数中具有可比性;另一方面体现了对检测完整性与操作安全性的同等高度重

视——在复杂曲面自动化视觉检测中,漏检(覆盖率不足)与碰撞均属于不可接受的失效模式,必须优先于效率予以保障。

4.2 IGWO

1) Logistic-tent 混沌映射

灰狼优化(grey wolf optimizer, GWO)^[21]算法具备参数敏感性低、易收敛的优势。然而,当处理复杂问题时,它依旧面临着容易过早收敛以及陷入局部最优解的困境。随机数初始化产生的种群个体在搜索空间中分布相对比较随机和分散。混沌映射具有遍历性,能够在一定范围内按照自身的规律不重复地遍历整个搜索空间。这意味着使用混沌映射初始化种群时,个体能够更均匀地分布在搜索空间中,从而增加了找到全局最优解的可能性。改进算法采用 Logistic-tent 混沌映射对种群进行初始化,其映射表达式如下:

$$x_{i+1} = \begin{cases} [r \cdot x_i \cdot (1 - x_i) + \frac{(4-r) \cdot x_i}{2}] \bmod 1, & x_i < 0.5 \\ [r \cdot x_i \cdot (1 - x_i) + \frac{(4-r)(1-x_i)}{2}] \bmod 1, & x_i \geq 0.5 \end{cases} \quad (11)$$

式中: \$r\$ 为控制参数,取值范围为 \$(0, 4)\$; \$\bmod 1\$ 表示对 1 取余。

2) 反向学习

反向学习^[22]作为优化算法初始化与搜索过程的优化技术,通过生成反向解拓宽搜索空间,提升种群多样性,避免算法过早陷入局部最优,从而有效提高搜索效率与收敛速度。混沌映射具备随机性、遍历性及规律性,能依据特定混沌规则在给定范围内生成伪随机序列,利用遍历性可更全面地探索搜索空间。将反向学习与混沌映射相结合,有助于优化算法在不同问题实例及初始条件下均展现良好性能,降低对初始值的依赖,增强算法的鲁棒性。基于上述背景,引入反射反向学习策略并结合混沌映射进行种群初始化。对于在 \$n\$ 维搜索空间中的点 \$x = (x_1, x_2, \dots, x_n)\$,其反向点 \$x^r = (x_1^r, x_2^r, \dots, x_n^r)\$ 计算公式如下:

$$x_i^r = l_i + u_i - x_i + \alpha \cdot \left(\frac{l_i + u_i}{2} - x_i \right) \quad (12)$$

式中: \$l, u\$ 分别为搜索空间的下限和上限; \$\alpha\$ 是范围在 \$[0, 1]\$ 的常数。

在种群初始化时,先根据混沌映射函数在搜索空间生成一定数量的个体构成初始种群 \$P\$,对于 \$P\$ 中每个个体 \$x\$,根据式(12)计算其反向个体,得到反向种群 \$P^r\$,合并初始种群 \$P\$ 和反向种群 \$P^r\$,根据目标函数评估每个个体的适应度,选择适应度最优的前 \$N\$ 个个体作为最终的初始种群,其中 \$N\$ 是种群的大小。

3) 动态收敛因子

GWO 算法中,收敛因子 a 呈线性递减,存在显著局限性。在优化起始阶段,搜索空间广阔,要求算法具备较强的全局搜索能力以充分探索潜在解。然而,线性递减的收敛因子致使算法在该阶段收敛速度过快,过早地将搜索范围限定于局部区域,增加了错过全局最优解的概率。当优化进程推进至局部搜索阶段,算法需对解进行精细调整以趋近最优值,此时线性递减的收敛因子无法灵活适配,难以赋予算法足够的探索能力,易使算法陷入局部最优,难以跳出。鉴于此,优化了 a 的参数控制策略,公式如下:

$$a_{\alpha} = a_{\max} \cdot e^{\left[\left(\frac{t}{T} \right)^2 \cdot \ln \left(\frac{a_{\min}}{a_{\max}} \right) \right]} \quad (13)$$

$$a_{\delta} = a_{\max} \cdot e^{\left[\left(\frac{t}{T} \right)^3 \cdot \ln \left(\frac{a_{\min}}{a_{\max}} \right) \right]} \quad (14)$$

$$a_{\beta} = \frac{a_{\alpha} + a_{\delta}}{2} \quad (15)$$

式中: a_{\max} 和 a_{\min} 为控制参数,取值范围分别为 $(1, 4)$ 和 $(0, 1.6)$; t 为当前迭代次数; T 表示最大迭代次数。

4) WOA 算法的螺旋气泡网狩猎机制

GWO 算法在优化求解时,主要靠 α, β, δ 狼引领种群更新位置,通过简单距离计算和系数调整逼近最优解。但面对复杂多模态搜索空间,其位置更新模式单一,缺乏深度与多样化搜索策略,前期易陷入局部较优区域,并且难以依靠自身跳出,导致优化结果常陷入局部最优。WOA 算法^[23]的发泡网狩猎机制,为解决上述问题提供了方案。该机制模拟鲸鱼螺旋式捕食路径,引入 GWO 后丰富了其搜索策略。满足特定条件时,种群个体按螺旋线方程更新位置,既向当前最优解靠近,又在其邻域精细搜索,增强了跳出局部最优的能力,提升搜索多样性,使改进算法能更好地平衡全局搜索与局部探索,提高找到全局最优解的概率。融合 WOA 后的 α 狼距离计算公式如下:

$$D_{\alpha} = \begin{cases} r_3 \cdot |C_1 \cdot X_{\alpha} - X|, p < 0.5 \\ r_4 \cdot e^{bl} \cdot \cos(2\pi l) \cdot |C_1 \cdot X_{\alpha} - X|, p \geq 0.5 \end{cases} \quad (16)$$

式中: r_3, r_4 是取值在 $[0, 1]$ 的随机向量; b 是一个常数,用来定义螺旋线的形状; l 是取值在 $(-1, 1)$ 的随机数。

5 算法比较分析

5.1 覆盖路径规划仿真结果分析

为系统验证所提出的 IGWO-WOA 在复杂曲面覆盖路径规划任务中的有效性,设计了与多种先进元启发式算法的对比仿真实验。实验以两个具有典型复杂几何特征的汽车方向盘点云模型为目标对象(图4),其包围盒

尺寸分别为 $376 \text{ mm} \times 362 \text{ mm} \times 140 \text{ mm}$ 和 $370 \text{ mm} \times 304 \text{ mm} \times 138 \text{ mm}$ 。在统一实验环境下,将所提算法与 GWO、WOA、麻雀搜索算法(sparrow search algorithm, SSA)^[24]、海洋捕食者算法(marine predators algorithm, MPA)^[25]以及哈里斯鹰优化算法(harris hawks optimization, HHO)^[26]进行性能对比。所有算法均采用 Python 语言在 VS Code 中实现,运行于 Windows 11 操作系统,硬件平台为 AMD Ryzen 7 5800H 处理器(主频 3.20 GHz)与 16.0 GB 内存。实验设置最大迭代次数为 300,种群规模为 120;本文算法的参数配置如表 1 所示,其余对比算法的参数均严格遵循其原始文献设定。



(a) 模型1
(a) Model 1

(b) 模型2
(b) Model 2

图4 目标对象点云模型

Fig. 4 Point cloud model of the target object

表1 算法主要参数

Table 1 Key parameters of the algorithm

参数	设定值
视锥体视角/ $^{\circ}$	60
视锥体远近平面/m	0.4, 0.05
偏移距离 Δx /m	0.1~0.2
控制参数 r	3.629
混沌映射初始值 x_0	0.657
反向学习常数 α	0.6
a_{\max}	2.2
a_{\min}	0.02
b	1
模型1 视点/位姿数	150/15
模型2 视点/位姿数	96/20

图5和6所示分别为模型1和模型2的仿真路径规划结果。其中,红色圆柱体表示视点在三维空间中的位置,其朝向对应视点的观测方向;绿色点云代表已被覆盖的区域,黑色点云则表示未被覆盖的部分;黑色连线为所生成的扫描路径轨迹。相较于其他对比算法,IGWO-WOA 算法规划出的路径更为平滑连续,且视点分布更加均匀。这种均匀性不仅显著减少了覆盖盲区,也有效提升了整体覆盖率与检测效率。此外,路径轨迹结构紧凑、逻辑清晰,避免了冗余迂回,从而显著缩短了遍历目标模型所需的总路径长度,在实际应用中可大幅降低时间与

资源开销。

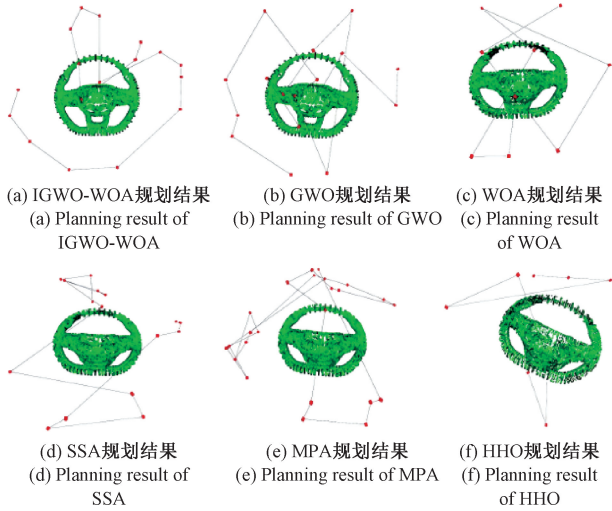


图 5 模型 1 规划结果

Fig. 5 The planning result of model 1

为降低随机性对实验结果的影响,上述 6 种算法均在两种模型上独立运行 10 次,并从目标函数平均最优值、平均路径长度、平均碰撞次数、优化平均耗时以及

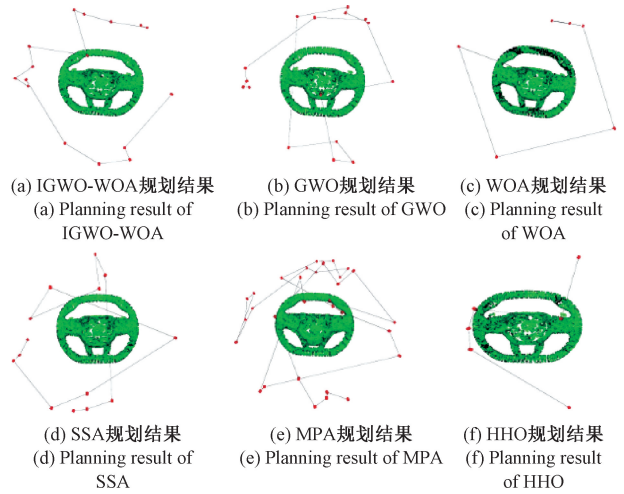


图 6 模型 2 规划结果

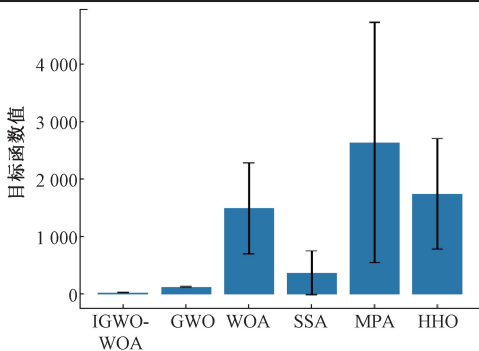
Fig. 6 The planning result of model 2

平均覆盖率等多个指标进行综合评估,具体结果如表 2 所示。同时,基于所得数据得到各算法目标函数值的标准差对比如图 7 所示。结果表明,IGWO-WOA 在两类模型下的目标函数值标准差均显著低于其他对比算法,体现出其运行稳定性与结果一致性。

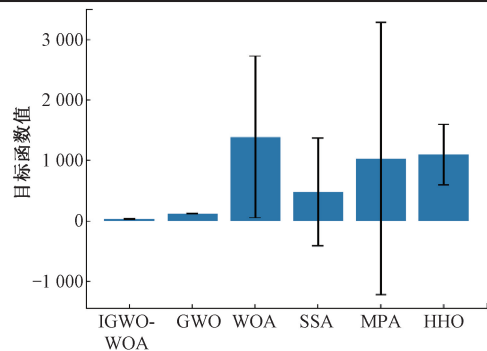
表 2 不同算法仿真数据平均值

Table 2 Average values of simulation data of different algorithms

检测规划方法	目标函数最优值	最短路径长度/m	平均碰撞次数	优化耗时/s	覆盖率/%	
模型 1	IGWO-WOA(本文)	30.39	12.67	0.0	1 076	99.7
	GWO	127.47	15.96	0.0	1 080	95.9
	WOA	1 492.25	6.31	0.6	1 068	87.5
	SSA	374.30	10.50	0.2	2 080	97.1
	MPA	2 694.93	35.71	2.6	1 092	99.88
	HHO	1 751.93	6.66	1.0	2 054	89.7
模型 2	IGWO-WOA(本文)	18.24	12.03	0.0	1 139	99.86
	GWO	119.05	13.59	0.0	1 146	97.3
	WOA	1 388.55	5.94	0.8	1 177	91.57
	SSA	477.73	9.43	0.4	2 260	98.68
	MPA	1 030.29	25.44	1.0	1 182	96.54
	HHO	1 096.79	5.50	0.2	2 153	87.98



(a) 模型 1 目标函数标准差
(a) Standard deviation of the objective function of model 1



(b) 模型 2 目标函数标准差
(b) Standard deviation of the objective function of model 2

图 7 目标函数标准差

Fig. 7 Standard deviation diagram of the objective function

结合表2中其他数据来看,IGWO-WOA在复杂曲面检测路径规划中展现出显著的综合性能优势。在模型1中,IGWO-WOA的目标函数最优值较GWO、WOA及SSA分别降低7.62%、97.9%与91.9%,其平均路径长度(12.67 m)较覆盖率较高的GWO(15.96 m)和MPA(35.71 m)分别缩短20.6%和64.5%,相比路径长度更短的SSA优化耗时较为可观,且完全避免碰撞。在模型2中,IGWO-WOA的目标函数最优值较GWO和HHO分别降低84.7%与83.4%,路径长度(12.03 m)较MPA(25.44 m)缩短52.7%,同时覆盖率提升至99.86%,较HHO(87.98%)提升13.5%。实验结果表明,所提算法通过混沌映射初始化与动态收敛因子策略,有效平衡了全局探索与局部开发能力,显著优化了多目标问题。进一步分析表明,所提算法在检测效率与安全性方面具有显著竞争力。其融合的螺旋狩猎机制通过引入鲸鱼优化算法的非线性搜索策略,将模型1与模型2的覆盖率分别提升至99.7%与99.86%,较次优算法平均提升10%~15%,且全程实现零碰撞路径规划。


5.2 消融实验分析

为验证IGWO-WOA中各改进模块的有效性与协同作用,设计了系统性的消融实验。在上述覆盖路径规划问题中,不同组合策略下目标函数值随迭代次数的变化趋势如图8所示。实验对比了GWO算法、仅引入单一改进机制(混沌映射、反向学习、动态收敛、螺旋气泡网)的变体,以及多种模块组合形式,最终与完整IGWO-WOA进行对比。

从图8可见,GWO算法虽具备较强的全局搜索能力,但其后期收敛速度较慢且易陷入局部最优,最终目标函数值稳定在约200。相比之下,仅引入混沌映射提升了种群多样性,初期搜索能力增强,但中期收敛停滞明显;仅反向学习通过构建对立解空间拓展搜索范围,在前100代表现出一定优势,但后期优化能力不足;仅动态收敛通过自适应调整收敛因子增强了局部开发能力,收敛速度快于GWO,但存在早熟收敛风险;仅螺旋气泡网模拟鲸鱼捕食行为,有效增强了局部精细搜索能力,但在全局探索阶段表现欠佳。

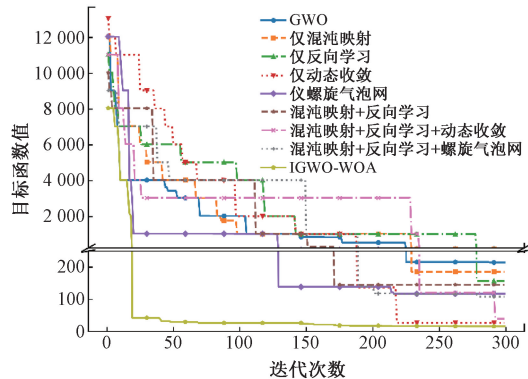
进一步地,当多个模块协同作用时,优化性能显著提升。例如,“混沌映射+反向学习”结合了多样性增强与解空间扩展优势,在前期快速下降并维持较低波动;而“混沌映射+反向学习+动态收敛”在保持良好探索能力的同时加快了收敛速度,最终目标函数值优于单一模块组合。特别地,“混沌映射+反向学习+螺旋气泡网”通过多机制互补,在全局探索与局部开发之间取得良好平衡,收敛过程平稳且最终解质量较高。

最终,IGWO-WOA在两种模型上均展现出最优异的优化性能:不仅在初始阶段迅速逼近最优区域,且在整个



(a) 模型1的消融实验收敛曲线

(a) Ablation study convergence curves for model 1



(b) 模型2的消融实验收敛曲线

(b) Ablation study convergence curves for model 2

图8 覆盖路径规划消融实验结果

Fig. 8 Results of the ablation study on coverage path planning

迭代过程中持续优化,最终目标函数值降到最低,表明其对复杂曲面覆盖路径规划问题具有较强的求解能力。这一结果充分说明,混沌映射、反向学习、动态收敛与螺旋气泡网等模块并非孤立作用,而是通过协同机制共同提升了算法的全局搜索能力、收敛速度与解的质量,验证了所提出的混合优化框架的有效性与必要性。

5.3 算法通用性分析

为进一步验证IGWO-WOA在通用优化问题上的泛化能力与鲁棒性,在广泛采用的CEC 2017基准测试集上开展了系统性对比实验。该测试集包含29个具有不同特性(如单峰、多峰、混合、复合等)的高维函数,能够全面评估算法的全局探索、局部开发及跳出局部最优的能力。实验选取了与5.1节相同的5种先进元启发式算法(GWO、WOA、SSA、MPA、HHO)作为对比基准,所有算法均在30维搜索空间下独立运行30次,最大迭代次数设为1000,种群规模为30,以确保实验设置的一致性。

如表3所示,IGWO-WOA在30个测试函数中取得了27次排名第1的优异表现,平均排名为1.10,显著优于其他对比算法(GWO为3.72,WOA为5.00,SSA为4.31,MPA为3.34,HHO为3.69)。特别是在多峰函数

(如 F3、F4、F7、F11、F13、F19、F29 等)和复合函数(如 F21~F30)上,IGWO-WOA 的均值与标准差均远低于其他方法,表明其不仅能够找到更优解,且求解稳定性极佳。例如,在高度复杂的 F19 函数上,IGWO-WOA 的平

均最优值为 4.10×10^4 ,而 GWO 高达 5.30×10^{10} ,相差超过 6 个数量级;在 F29 上,IGWO-WOA 的标准差为 6.45×10^3 ,而 SSA 高达 9.80×10^{11} ,显示出极强的抗波动能力。

表 3 6 种算法在 CEC2017 基准函数上的性能对比

Table 3 Performance comparison of 6 algorithms on the CEC2017 benchmark functions

函数	统计结果	GWO	WOA	SSA	MPA	HHO	IGWO-WOA
F1	均值	2.59×10^9	1.76×10^{10}	2.87×10^6	1.66×10^9	3.24×10^8	2.71×10^4
	标准差	1.69×10^9	6.50×10^9	2.22×10^6	1.08×10^9	1.72×10^8	1.11×10^4
	排名	5	6	2	4	3	1
F3	均值	9.42×10^3	4.54×10^4	1.91×10^2	2.93×10^3	6.09×10^3	1.00×10^{-1}
	标准差	6.01×10^3	1.92×10^4	1.24×10^2	2.36×10^3	2.30×10^3	6.00×10^{-2}
	排名	5	6	2	3	4	1
F4	均值	2.76×10^2	2.73×10^3	9.22×10^2	2.34×10^3	3.28×10^2	3.54×10^1
	标准差	3.09×10^2	3.01×10^3	1.88×10^3	3.21×10^3	1.28×10^2	1.65×10^1
	排名	2	6	4	5	3	1
F5	均值	4.24×10^3	3.12×10^4	7.88×10^3	2.75×10^3	2.11×10^3	2.99×10^2
	标准差	3.86×10^3	1.05×10^4	2.50×10^3	2.15×10^3	4.87×10^2	6.99×10^1
	排名	4	6	5	3	2	1
F6	均值	4.02×10^{-1}	1.00×10^{-2}	2.00×10^{-2}	1.00×10^0	5.02×10^{-5}	8.34×10^{-2}
	标准差	1.00×10^{-2}	1.00×10^{-2}	0.00×10^0	0.00×10^0	3.21×10^{-2}	1×10^{-1}
	排名	5	2	3	6	1	4
F7	均值	1.45×10^5	6.80×10^5	9.65×10^3	9.03×10^4	3.27×10^4	3.50×10^2
	标准差	1.47×10^5	1.83×10^5	2.40×10^3	8.11×10^4	1.97×10^4	8.43×10^1
	排名	5	6	2	4	3	1
F8	均值	2.85×10^2	8.69×10^2	8.51×10^2	3.53×10^2	5.42×10^2	2.22×10^2
	标准差	1.24×10^2	1.04×10^2	2.12×10^1	1.21×10^2	7.80×10^1	7.37×10^1
	排名	2	6	5	3	4	1
F9	均值	8.12×10^0	2.00×10^1	1.27×10^1	6.71×10^1	1.29×10^1	1.09×10^0
	标准差	3.36×10^0	9.00×10^0	1.67×10^0	3.33×10^0	2.66×10^0	7.30×10^{-1}
	排名	2	5	3	6	4	1
F10	均值	3.47×10^3	6.09×10^3	5.52×10^3	5.45×10^3	4.41×10^3	3.06×10^3
	标准差	1.31×10^3	1.15×10^3	1.33×10^3	2.36×10^3	5.88×10^2	6.08×10^2
	排名	2	6	5	4	3	1
F11	均值	1.12×10^5	1.92×10^7	6.51×10^4	4.77×10^5	1.04×10^5	2.61×10^4
	标准差	2.94×10^4	5.79×10^7	1.78×10^4	1.22×10^6	2.66×10^4	1.52×10^4
	排名	4	6	2	5	3	1
F12	均值	2.87×10^8	2.74×10^8	6.31×10^8	2.85×10^7	7.33×10^7	4.91×10^5
	标准差	8.41×10^8	4.66×10^8	1.71×10^9	1.87×10^7	5.80×10^5	1.70×10^5
	排名	5	4	6	2	3	1
F13	均值	1.24×10^8	4.15×10^8	9.48×10^4	3.84×10^6	1.26×10^7	4.13×10^4
	标准差	2.41×10^8	4.46×10^8	1.01×10^5	4.64×10^6	7.32×10^6	6.49×10^3
	排名	5	6	2	3	4	1
F14	均值	5.03×10^5	7.53×10^5	2.06×10^6	3.21×10^5	1.47×10^6	4.73×10^4
	标准差	4.77×10^5	7.74×10^5	2.14×10^6	2.87×10^5	5.80×10^5	2.72×10^4
	排名	3	4	6	2	5	1
F15	均值	2.86×10^6	5.90×10^7	1.96×10^8	6.40×10^5	4.14×10^6	6.20×10^4
	标准差	3.32×10^6	1.01×10^8	4.46×10^8	7.55×10^5	4.27×10^6	1.48×10^4
	排名	3	5	6	2	4	1
F16	均值	3.02×10^8	1.08×10^6	2.43×10^5	7.80×10^5	4.66×10^5	6.04×10^2
	标准差	7.13×10^8	1.45×10^6	3.92×10^5	1.52×10^6	5.21×10^5	7.96×10^2
	排名	6	5	2	4	3	1

续表 3

函数	统计结果	GWO	WOA	SSA	MPA	HHO	IGWO-WOA
F17	均值	5.35×10^4	8.96×10^4	1.09×10^{12}	4.10×10^4	1.05×10^5	1.29×10^3
	标准差	1.91×10^4	7.04×10^4	3.44×10^{12}	1.41×10^4	4.54×10^4	4.45×10^2
	排名	3	4	6	2	5	1
F18	均值	4.41×10^5	4.66×10^5	1.54×10^6	4.95×10^5	1.07×10^6	4.84×10^5
	标准差	3.79×10^5	5.75×10^5	3.20×10^6	2.76×10^5	7.92×10^5	1.58×10^4
	排名	1	2	6	4	5	3
F19	均值	5.30×10^{10}	1.95×10^7	7.32×10^4	4.16×10^6	2.40×10^9	4.10×10^4
	标准差	1.67×10^{11}	2.05×10^7	4.32×10^4	1.20×10^7	7.59×10^9	1.84×10^4
	排名	6	4	2	3	5	1
F20	均值	9.43×10^2	1.35×10^4	1.23×10^4	6.52×10^2	5.44×10^3	1.80×10^2
	标准差	5.98×10^2	3.64×10^3	3.97×10^3	2.76×10^2	1.26×10^3	1.40×10^2
	排名	3	6	5	2	4	1
F21	均值	2.25×10^3	8.99×10^3	4.25×10^3	1.72×10^3	1.58×10^3	1.05×10^2
	标准差	1.70×10^3	8.45×10^3	3.49×10^3	7.80×10^2	7.56×10^2	9.00×10^{-1}
	排名	4	6	5	3	2	1
F22	均值	2.02×10^2	2.40×10^3	2.85×10^3	2.04×10^2	2.72×10^3	1.79×10^2
	标准差	1.44×10^1	1.45×10^3	1.27×10^3	1.68×10^1	1.07×10^3	7.12×10^0
	排名	2	4	6	3	5	1
F23	均值	4.29×10^3	2.71×10^4	1.04×10^4	4.15×10^3	2.86×10^3	2.63×10^2
	标准差	2.32×10^3	1.08×10^4	1.66×10^4	3.57×10^3	1.09×10^3	1.33×10^2
	排名	4	6	5	3	2	1
F24	均值	4.00×10^3	2.16×10^4	5.40×10^2	3.09×10^3	1.92×10^3	2.09×10^2
	标准差	1.38×10^3	9.23×10^3	3.94×10^2	1.95×10^3	8.43×10^2	3.08×10^0
	排名	5	6	2	4	3	1
F25	均值	5.61×10^2	1.34×10^3	8.81×10^2	5.29×10^2	7.21×10^2	4.29×10^2
	标准差	8.95×10^1	4.17×10^2	2.77×10^2	6.28×10^1	1.11×10^2	8.53×10^0
	排名	3	6	5	2	4	1
F26	均值	1.02×10^3	7.47×10^3	5.17×10^3	9.34×10^2	1.54×10^3	8.71×10^2
	标准差	1.87×10^2	4.17×10^2	2.76×10^3	6.86×10^1	1.07×10^3	2.05×10^1
	排名	3	6	5	2	4	1
F27	均值	5.77×10^2	1.47×10^3	1.33×10^3	5.65×10^2	1.29×10^3	5.81×10^2
	标准差	4.65×10^1	3.67×10^2	3.32×10^2	2.41×10^1	4.10×10^2	1.83×10^1
	排名	2	6	5	1	4	3
F28	均值	5.08×10^2	1.19×10^3	1.48×10^3	4.82×10^2	6.48×10^2	1.22×10^2
	标准差	5.67×10^1	7.40×10^2	1.52×10^3	2.76×10^1	2.11×10^2	1.26×10^2
	排名	3	5	6	2	4	1
F29	均值	1.03×10^7	1.60×10^8	3.13×10^{11}	1.35×10^7	1.22×10^8	1.08×10^4
	标准差	1.26×10^7	2.10×10^8	9.80×10^{11}	2.07×10^7	2.77×10^8	6.45×10^3
	排名	2	5	6	3	4	1
F30	均值	1.39×10^{10}	9.91×10^8	8.62×10^8	1.39×10^7	9.03×10^7	8.67×10^4
	标准差	4.37×10^{10}	2.54×10^9	1.53×10^9	2.04×10^7	1.18×10^8	2.81×10^4
	排名	6	5	4	2	3	1
	平均排名	3.72	5.00	4.31	3.34	3.69	1.10
	最终排名	4	6	5	2	3	1

上述结果充分说明,IGWO-WOA 中引入的混沌映射初始化、反向学习策略、动态收敛因子及螺旋狩猎机制不仅在面向复杂曲面覆盖路径规划这一特定任务中有效,而且在广泛的连续优化问题上同样具备卓越的搜索性能与鲁棒性。其优异表现源于多策略的协同作用;混沌映射与反向学习增强了初始种群的多样性与全局探索能力;动态收敛因子平衡了不同阶段的开发强度;而融合

WOA 的螺旋气泡网机制则有效提升了局部精细搜索与跳出局部最优的能力。

6 结 论

针对复杂曲面视觉检测中的覆盖路径规划问题,提出一种视点与路径协同优化的方法。本文方法基于轴对

齐包围盒细分与随机偏移生成候选视点位置,结合球坐标系采样确定观测方向,并构建融合景深、视场角、可见性及遮挡约束的视锥体覆盖评估模型。进一步地设计 IGWO-WOA 优化算法,通过混沌映射初始化、反向学习、动态收敛因子与螺旋狩猎机制,在统一框架下同步优化视点选择与访问顺序。实验表明,该方法在方向盘点云模型上实现 99.7% 以上的覆盖率,路径长度显著缩短,全程无碰撞,且具备优异的稳定性与泛化能力。此外,在 CEC 2017 基准测试集上的泛化实验进一步证明,IGWO-WOA 在广泛连续优化问题中亦具备优越的全局探索与局部开发能力。

然而,本文方法仍存在一定局限,一方面,当前方法主要适用于外表面检测,对具有深凹腔或强内部遮挡的几何结构(如杯状物体内壁或发动机缸孔等)覆盖能力有限,难以有效观测内表面区域。为此,未来可深入研究曲面形状特征对算法性能的影响机制,针对性调整视点采样策略(如采用自适应采样)、优化覆盖评估模型(引入精确几何模型或智能算法)以提升对复杂曲面的适应性;另一方面,算法尚未在真实机器人系统中验证,后续工作将致力于将所提算法集成至实际视觉检测系统中,结合机械臂运动学约束验证其在工业现场环境下的可行性、实时性与工程实用性,推动研究成果向智能制造场景落地转化。

参考文献

- [1] 李艳生,万勇,张毅,等.基于人工蜂群-自适应遗传算法的仓储机器人路径规划[J].仪器仪表学报,2022,43(4):282-290.
LI Y SH, WAN Y, ZHANG Y, et al. Path planning of warehouse robots based on artificial bee colony-adaptive genetic algorithm [J]. Chinese Journal of Scientific Instrument, 2022, 43(4): 282-290.
- [2] 何世鹏,金世俊.结合蚁群算法和萤火虫算法的无人船路径规划[J].电子测量技术,2023,46(19):82-86.
HE SH P, JIN SH J. Path planning of unmanned surface vehicle combining ant colony algorithm and firefly algorithm [J]. Electronic Measurement Technology, 2023, 46(19): 82-86.
- [3] TAN C S, MOHD-MOKHTAR R, ARSHAD M R. A comprehensive review of coverage path planning in robotics using classical and heuristic algorithms [J]. IEEE Access, 2021, 9: 119310-119342.
- [4] ALMADHOUN R, TAHA T, SENEVIRATNE L, et al. Multi-robot hybrid coverage path planning for 3D reconstruction of large structures [J]. IEEE Access, 2021, 10: 2037-2050.
- [5] HÖFFMANN M, PATEL S, BÜSKENS C. Optimal guidance track generation for precision agriculture: A review of coverage path planning techniques [J]. Journal of Field Robotics, 2024, 41(3): 823-844.
- [6] HOLLINGER G A, ENLOT B J, HOVER F S, et al. Active planning for underwater inspection and the benefit of adaptivity [J]. The International Journal of Robotics Research, 2013, 32(1): 3-18.
- [7] XI M M, WANG Y Q, LIU H B, et al. Inspection path planning of complex surface based on one-step inverse approach and curvature-oriented point distribution [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-11.
- [8] SCOTT W R. Model-based view planning [J]. Machine Vision and Applications, 2009, 20(1): 47-69.
- [9] PAN S C, WEI H. A global generalized maximum coverage-based solution to the non-model-based view planning problem for object reconstruction [J]. Computer Vision and Image Understanding, 2023, 226: 103585.
- [10] JING W. Coverage planning for robotic vision applications in complex 3d environment [D]. Pittsburgh: Carnegie Mellon University, 2017.
- [11] MOSBACH D, GOSPODNETIĆ P, RAUHUT M, et al. Feature-driven viewpoint placement for model-based surface inspection [J]. Machine Vision and Applications, 2021, 32: 1-21.
- [12] 刘洪鹏,赵文政,刘银华,等.测量不确定度约束下的结构光检测视点规划方法[J].计算机集成制造系统,2022,28(4):1079-1086.
LIU H P, ZHAO W ZH, LIU Y H, et al. Viewpoint planning method for structured light detection under measurement uncertainty [J]. Computer Integrated Manufacturing Systems, 2022, 28(4): 1079-1086.
- [13] PHUNG M D, QUACH C H, DINH T H, et al. Enhanced discrete particle swarm optimization path planning for UAV vision-based surface inspection [J]. Automation in Construction, 2017, 81: 25-33.
- [14] CAO C, ZHANG J, TRAVERS M, et al. Hierarchical coverage path planning in complex 3d environments [C]. 2020 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2020: 3206-3212.
- [15] MOHAMMADIKAJI M, BERGMANN S, IRGENFRID S, et al. Inspection planning for optimized coverage of geometrically complex surfaces [C]. 2018 Workshop on Metrology for Industry 4.0 and IoT. IEEE, 2018: 52-67.
- [16] BIRCHER A, ALEXIS K, BURRI M, et al. Structural inspection path planning via iterative viewpoint resampling with application to aerial robotics [C]. 2015 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2015: 6423-6430.

- [17] JING W, POLDER J, TAO P Y, et al. Model-based coverage motion planning for industrial 3D shape inspection applications [C]. 2017 13th IEEE Conference on Automation Science and Engineering (CASE). IEEE, 2017: 1293-1300.
- [18] 陈丽, 陈洋, 杨艳华. 面向三维结构视觉检测的无人机覆盖路径规划 [J]. 电子测量与仪器学报, 2023, 37(2): 1-10.
CHEN L, CHEN Y, YANG Y H. UAV Coverage path planning for 3D structural vision inspection [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(2): 1-10.
- [19] 顿启鹏, 毋涛, 邓魏永. 点云数据的补全与精简算法研究 [J]. 国外电子测量技术, 2023, 42(8): 111-116.
DUN Q P, WU T, DENG W Y. Research on completion and simplification algorithm of point cloud data [J]. Foreign Electronic Measurement Technology, 2023, 42(8): 111-116.
- [20] KAISER J P, GÄBELE J, KOCH D, et al. Adaptive acquisition planning for visual inspection in remanufacturing using reinforcement learning [J]. Journal of Intelligent Manufacturing, 2024, 36: 4867-4893.
- [21] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer [J]. Advances in Engineering Software, 2014, 69: 46-61.
- [22] YU X B, XU W Y, LI C L. Opposition-based learning grey wolf optimizer for global optimization [J]. Knowledge-Based Systems, 2021, 226: 107139.
- [23] MIRJALILI S, LEWIS A. The whale optimization algorithm [J]. Advances in Engineering Software, 2016, 95: 51-67.
- [24] XUE J, SHEN B. A novel swarm intelligence optimization approach: Sparrow search algorithm [J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.
- [25] FARMARZI A, HEIDARINEJAD M, MIRJALILI S, et al. Marine predators algorithm: A nature-inspired metaheuristic [J]. Expert Systems with Applications, 2020, 152: 113377.
- [26] HEIDARI A A, MIRJALILI S, FARIS H, et al. Harris hawks optimization: Algorithm and applications [J]. Future Generation Computer Systems, 2019, 97: 849-87.

作者简介



禾家辉, 2023 年于哈尔滨工业大学获得学士学位, 现为哈尔滨工业大学硕士研究生, 主要研究方向为复杂曲面视觉检测的覆盖路径规划。

E-mail: 23S136122@stu.hit.edu.cn

He Jiahui received his B. Sc. degree from Harbin Institute of Technology in 2023. He is now a M. Sc. candidate at Harbin Institute of Technology. His main research interest includes coverage path planning for visual inspection of complex surfaces.



金晶 (通信作者), 2008 年于哈尔滨工业大学获得博士学位, 现为哈尔滨工业大学教授, 主要研究方向为智慧农业、工业仿真软件国产化替代、工业视觉检测等。

E-mail: jinjinghit@hit.edu.cn

Jin Jing (Corresponding author) received her Ph. D. degree from Harbin Institute of Technology in 2008. She is now a professor at Harbin Institute of Technology. Her main research interests include smart agriculture, domestic substitution of industrial simulation software, and industrial visual inspection.