

自适应差分进化算法在不同环境下实现高效无人机路径规划

陈德旺¹, 陈秀彬², 孟振宇¹, Bahattin Türetken³

(1. 福建理工大学计算机与数据科学学院, 福建 福州 350000;

2. 福建理工大学人工智能与交通工程学院, 福建 福州 350000;

3. 科贾埃利大学工程学院, 土耳其 科贾埃利 41030)

摘要: 无人机 (UAV) 路径规划问题因搜索空间的高维特性及复杂操作约束条件而极具挑战性。为突破此局限, 提出一种融合三项协同策略的改进型差分进化 (DE), 首先引入基于泊松分布的机制判断下一代突变成功率, 并自适应地将搜索资源优先分配给更有效的突变策略; 其次采用余弦相似性约束引导种群演化方向, 减少方向性分散并提升收敛效率; 最后设计分阶段自适应参数控制策略, 在初期强化全局探索能力, 后期加速收敛进程, 同时保持种群多样性。通过协同整合自适应策略选择、演化方向引导与动态参数调整, 所提算法实现了探索与开发之间的平衡。在 CEC2017 基准测试集及基于真实数字高程模型 (DEM) 数据构建的多个无人机路径规划仿真场景的实验中, 所提算法在收敛速度、稳定性及解质量等方面展现出较好的竞争力。

关键词: 无人机; 差分进化; 泊松分布; 余弦相似性; 参数控制

中图分类号: TP39

文献标志码: A

doi: 10.11959/j.issn.2096-6652.ZNKX26047

Adaptive differential evolution for efficient unmanned aerial vehicle path planning in different environments

Chen Dewang¹, Chen Xiubin², Meng Zhenyu¹, Bahattin Türetken³

1. School of Computer Science and Data Science, Fujian University of Technology, Fuzhou 350000, China

2. School of Artificial Intelligence and Transportation Engineering, Fujian University of Technology, Fuzhou 350000, China

3. Faculty of Engineering, Kocaeli University, Kocaeli 41030, Türkiye

Abstract: The unmanned aerial vehicle (UAV) path planning problem is highly challenging due to the high dimensionality of the search space and presence of complex operational constraints. To address these limitations, an enhanced differential evolution (DE) algorithm was proposed that integrates three synergistic strategies. First, a Poisson distribution based mechanism was introduced to estimate the mutation success rate in the next generation, enabling adaptive allocation of search resources toward more effective mutation strategies. Second, cosine similarity constraint was employed to guide the evolutionary direction of the population, thereby reducing directional divergence and improving convergence efficiency. Third, a staged adaptive parameter control scheme was designed, which enhances global exploration in the early phase and accelerates convergence in later phase while maintaining population diversity. By collaboratively integrating adaptive strategy selection, evolutionary direction guidance, and dynamic parameter adjustment, the proposed method achieves a balanced trade off between exploration and exploitation. Experimental results of the CEC2017 benchmark suite

收稿日期: 2026-04-13; 修回日期: 2026-06-01

通信作者: 孟振宇, mzy1314@gmail.com

基金项目: 福建省第三批创新之星人才计划 (No.GY-Z23068); 福建理工大学科研基金 (No.GY-Z22071); 福建省财政厅教育科研专项资金 (No.GY-Z21001)

Foundation Items: The Innovation Star Talent Program of the Third Batch in Fujian Province (No.GY-Z23068), The Scientific Research Foundation of Fujian University of Technology (No.GY-Z22071), The Special Fund for Education and Scientific Research of Fujian Provincial Department of Finance (No.GY-Z21001)

and multiple UAV path planning simulation scenarios constructed from real digital elevation model (DEM) data demonstrate that the proposed algorithm achieves competitive performance in convergence speed, stability, and solution quality.

Key words: unmanned aerial vehicle, differential evolution, Poisson distribution, cosine similarity, parameter control

0 引言

无人机由于其成本低、无人驾驶、部署灵活以及适应复杂环境能力强等优点,已在各个领域被广泛应用^[1-3]。在复杂的环境下,规划航线还需满足作业环境带来的安全限制和无人机可行性的限制^[4]。路径规划是保障无人机任务顺利执行并有效规避运行环境中各类威胁的关键环节。在无人机安全方面实现无碰撞和可行运动的路径规划仍是一个充满挑战的问题。

随着无人机路径规划问题的深入研究,国内外学者在无人机路径规划中已取得了很大的成就,例如,快速探索随机树算法、A*算法以及自然启发算法等^[5-6]。密度梯度快速扩展随机树(DG-RRT)算法是基于快速探索随机树(rapidly-exploring random tree, RRT)改进的,在提升初始解效率的同时降低路径成本,并验证了其在无人机路径规划中的有效性^[7]。Lyu等^[8]通过4种策略提升了收敛速度与精度,并在基准测试与无人机路径规划中展现出优越的性能与鲁棒性。球面向量粒子群优化(PSO)算法采用球形矢量将粒子的位置与无人机的速度、转弯角和爬升/俯冲角相对应,从而更高效地搜索配置空间并生成可行最优路径^[9]。近年来,受自然启发的方法在路径规划中越来越普遍,因为它在应对无人机动态约束方面有效,并且具备在复杂场景中寻找全局最优方法的能力。多种受自然启发的算法已被开发用于无人机路径规划,如遗传算法、灰狼算法、人工蜂群和差分进化^[10]等。差分进化(differential evolution, DE)具有全局搜索能力强、参数少、收敛速度快等优势,使得该类算法常被用于复杂环境、多约束条件下的无人机路径规划,并引入了多种变体^[11]。

DE源于生物进化算法,继承了群体搜索、变异、交叉和选择,主要通过对个体的每个维度施加向量差值扰动来实现个体适应度的最优化,可避免处于局部最优状态且仅有3个控制参数:种群规模(population size, PS)、变异因子(mutation factor, F)和交叉概率(crossover rate, CR)^[12-13]。近年来,有不少差分进化变体被提出,由于寻找合适的参数

通常需要依赖先验知识和大量的实验调优,而不同问题的最优参数设置可能存在差异,因此自适应机制自然被引入以提升算法性能^[14-15]。Brest等^[16]提出了首个自适应DE算法,即jDE,该方法能够促使优化过程中产生更优的控制参数,具备更优控制参数的个体更有可能在选择过程中存活。Qin等^[17]提出的自适应差分进化(SaDE)运用历史信息 and 个体适应度的变化自适应地调整变异策略和控制参数,能够适应不同的优化问题。在此基础上,Zhang等^[18]通过引入突变交叉优化、自适应引导和精英扰动机制,有效提升了无人机在复杂山地环境下三维轨迹规划的收敛性和全局搜索能力。Zhang等^[19]提出了集体集成学习差分进化框架,从维度层面实现多策略协同进化,使算法能够更有效地应对变量异质性显著的复杂与混合优化问题。Zhou等^[20]通过非线性种群规模缩减与选择性前100%优秀(p-best)个体机制协同调控搜索过程,在兼顾早期探索与后期开发的同时避免固定参数偏置,并结合档案引导变异策略,有效提升了算法在复杂与高维优化问题中的收敛性能与鲁棒性。Song等^[21]引入分阶段的非线性参数自适应机制、供体向量扰动的试验向量生成策略,以及融合分布与适应度信息的停滞检测与对立学习干预方法,在保持搜索稳定性的同时有效增强了种群多样性与高维优化性能。Zhang等^[22]从“维度差异”的视角重新审视DE中的信息继承问题,并通过维度自适应CR分配与CR引导策略选择,系统性地提升了差分进化在高维、复杂优化问题中的性能与稳定性。Luo等^[23]通过引入分层选择变异、基于距离的概率选择以及与停滞识别相匹配的缩放因子控制策略,显著提升了算法在复杂优化问题中的全局搜索能力与稳定性。Chai等^[24]通过构建多策略融合的差分进化框架,将多种互补的搜索策略有机结合。

尽管上述改进型差分进化算法从控制参数自适应、变异策略优化、种群规模调整、多策略协同以及集成学习等多个角度提升了算法性能,并在复杂优化问题和无人机路径规划领域取得了良好的效果,但仍存在一些值得进一步研究的问题。首先,现有自适应差分进化算法大多依赖历史成功个体信

息、历史参数分布或历史策略表现来调整搜索行为,例如jDE、SaDE以及相关改进方法均属于此类机制。这种基于历史经验的调整方式虽然能够提高算法的自适应能力,但对当前种群搜索状态的实时反馈利用不足,当搜索环境发生变化或种群演化进入停滞阶段时,容易导致参数更新滞后,从而影响搜索效率^[25]。其次,部分研究通过精英引导、p-best选择、种群缩减以及多策略融合等方式增强算法的开发能力和收敛速度。然而,随着种群逐渐向优势区域聚集,种群多样性可能快速下降,从而导致搜索空间覆盖能力减弱。在复杂、多峰以及高维优化问题中,这种现象容易引起早熟收敛,使算法陷入局部最优解附近^[26]。此外,近年来提出的多策略融合和集成学习框架虽然能够充分利用不同搜索机制的优势,但往往需要设计复杂的策略选择机制、权重分配机制以及协同演化机制,增加了算法结构复杂度和参数调节难度。同时,这类方法更多关注搜索策略之间的协同优化,而较少从搜索过程本身出发对种群演化方向进行显式建模与分析。

综上所述,现有改进型差分进化算法虽然在参数调控与策略设计方面取得了显著进展,但针对无人机路径规划这类高维复杂优化问题(即无人机路径规划需要对多个航点进行描述,其维度容易随着航点的增加而增加),可能导致优化过程中的收敛速度变慢。上述不足在一定程度上限制了算法的收敛效率和寻优性能^[27]。为此,本文从变异策略选择、历史淘汰试用载体复用以及自适应参数控制3个方面对传统差分进化算法进行改进,提出一种增强型差分进化算法,通过构建基于泊松分布的策略选择机制、基于余弦相似度的方向引导机制以及分阶段参数控制机制,提高算法在复杂无人机路径规划问题中的搜索效率、收敛性能和解的质量。本文的主要贡献如下。

(1) 提出了一种基于泊松分布的突变成功率预测机制。通过对下一代突变成功率进行建模,并与当前代的实际成功率进行对比,自适应地选择变异策略。当预测成功率较高时,采用“current-topbest/1”策略以加强局部开发;否则,切换为精英引导突变策略以增强全局探索能力。该方法能够根据搜索状态动态调整策略选择,从而在探索与开发之间取得更好的平衡。

(2) 引入了基于余弦相似度的进化方向一致性评估机制。通过衡量种群整体演化方向与精英个体

引导方向之间的一致性,当检测到偏离时,利用历史被淘汰的试验向量生成新个体,以对种群搜索方向进行修正。该机制有助于避免无效搜索,提高进化过程的稳定性与收敛效率。

(3) 设计了一种分阶段自适应参数控制策略。在进化初期,通过较大的参数设置促进种群的广泛探索;随着迭代推进,逐步调整参数以增强局部开发能力,并结合历史成功参数信息进行更新。该策略能够使算法在不同阶段匹配相应的搜索需求,从而提升整体优化性能与鲁棒性。

(4) 通过基准测试函数评估了所提算法的性能,并通过应用于三维无人机路径规划进一步验证了其实际可行性。

1 无人机路径规划的数学模型

1.1 场景描述

本文研究复杂三维环境下的无人机路径规划问题。随着无人机在军事侦察、目标监测、应急救援、物流运输以及环境巡检等领域的广泛应用,路径规划能力已成为影响任务执行效率和飞行安全的重要因素^[28]。在实际飞行过程中,无人机通常需要在复杂的三维空间环境中从起始位置到达目标位置,而飞行区域内往往存在山体、建筑物等障碍物,以及禁飞区、雷达探测区等威胁区域,这些因素都会对无人机的飞行路径产生影响。因此,如何在复杂环境中规划一条安全、高效且可行的飞行路径成为亟须解决的问题。

在路径规划过程中,无人机不仅需要满足避障和规避威胁区域等环境约束,还需考虑自身的飞行性能约束,例如最大转弯角、最大爬升角以及飞行高度范围等限制。由于该问题同时涉及多种约束条件和优化目标,具有高维、非线性以及多峰搜索空间等特点,因此本质上属于复杂的约束优化问题。基于此,本文采用航点对无人机飞行轨迹进行描述,将路径规划问题转化为连续优化问题,并构建相应的目标函数与约束模型,为后续优化算法求解提供基础。

1.2 数学模型

基于上述任务场景与约束条件,本文将无人机路径规划问题严谨地表述为成本最小化问题,其目标函数包含4个基本要素:路径长度、威胁规避、高度约束以及转向与爬升平滑性^[29]。这些要素被综合整合,既体现轨迹最优性要求,又满足无人机

飞行的实际操作约束, 从而确保规划路径的可行性、安全性和平滑性。

(1) 路径长度

无人机从初始位置出发, 通过遵循有序航点序列抵达目的地。更短的轨迹对应更低的路径长度成本。飞行路径由 N 个航点序列定义, 每个航点用 W 表示。因此, 完整的无人机轨迹如式 (1) 所示。

$$P = \{W_{i,1}, W_{i,2}, \dots, W_{i,N}\} \quad (1)$$

其中, $W_{i,j}$ 为三维坐标, $W_{i,j} = (x_{i,j}, y_{i,j}, z_{i,j})$ 。路径长度成本定义为相邻航点间欧几里得距离之和, 如式 (2) 和式 (3) 所示。

$$d(\overrightarrow{W_{i,j}W_{i,j+1}}) = \sqrt{(x_{i,j+1} - x_{i,j})^2 + (y_{i,j+1} - y_{i,j})^2 + (z_{i,j+1} - z_{i,j})^2} \quad (2)$$

$$C_1 = \sum_{j=1}^{N-1} d(\overrightarrow{W_{i,j}W_{i,j+1}}) \quad (3)$$

其中, C_1 代表路径总长度的成本, $d(\cdot)$ 表示相邻航点之间的距离。

(2) 威胁规避

将环境中的建筑、树木以及禁飞区等当作障碍物或者威胁源。本文把每个威胁建模为竖直圆柱, 其中, 威胁的半径为 R_t , 无人机的直径为 D_{UAV} , 危险缓冲距离为 d_{safe} , 如图1所示。本文要评估一段路径 (相邻航点构成的线段) 到威胁的距离通常是使用线段到障碍中心的最短距离, 即 $d_{i,j}$ 。将这一段路径到威胁的最小距离看作单个威胁的代价, 将一条路径中所有的单个威胁代价全部加起来就是总的威胁代价, 使用 C_2 表示, 单个威胁代价用 T 表示, 一条路径中的威胁总数用 K 表示, 其中 T 的计算式如式 (4) 所示, C_2 的计算式如式 (5) 所示。

$$T_{i,j} = \begin{cases} 0, & d_{i,j} > d_{safe} + D_{UAV} + R_t \\ d_{safe} + D_{UAV} + R_t - d_{i,j}, & D_{UAV} + R_t < d_{i,j} \leq d_{safe} + D_{UAV} + R_t \\ \infty, & d_{i,j} \leq D_{UAV} + R_t \end{cases} \quad (4)$$

$$C_2 = \sum_{j=1}^K T_{i,j} \quad (5)$$

若无人机进入危险缓冲区并与威胁目标发生碰撞, 则该路径被视为不可行。

(3) 高度约束

飞行过程中, 无人机高度限定在最小允许高度 h_{min} 和最大允许高度 h_{max} 构成的取值区间内。为保




图1 威胁规避成本

证无人机平稳稳定的飞行, 当高度偏离该许可区间的中心点时将施加惩罚项。每个航点的高度成本 C_3 由式 (7) 给出。若无人机高度超出规定范围, 则该航段路径被视为不可行。

$$H_{i,j} = \begin{cases} \left| h_{i,j} - \frac{h_{max} + h_{min}}{2} \right|, & h_{min} \leq h_{i,j} \leq h_{max} \\ \infty, & \text{其他} \end{cases} \quad (6)$$

$$C_3 = \sum_{j=1}^N H_{i,j} \quad (7)$$

其中, $h_{i,j}$ 表示无人机在当前航点处的飞行高度。

(4) 转向与爬升平滑性

转向与爬升角度计算如图2所示, 无人机的转向与爬升动作会导致能耗增加。为保证无人机平稳且节能地飞行, 在目标函数中引入了平滑度代价项。其中, $\theta_{i,j}$ 代表无人机的转弯角度, $\phi_{i,j}$ 表示爬升角度。基于向量投影角度的详细计算方法如下。




图2 转向与爬升角度计算

$$\theta_{i,j} = \arctan \left(\frac{\left\| \overrightarrow{W'_{i,j} W'_{i,j+1}} \times \overrightarrow{W'_{i,j+1} W'_{i,j+2}} \right\|}{\left\| \overrightarrow{W'_{i,j} W'_{i,j+1}} \right\| \times \left\| \overrightarrow{W'_{i,j+1} W'_{i,j+2}} \right\|} \right) \quad (8)$$

$$\theta_{i,j} = \begin{cases} \theta_{\max}, & |\theta| > \theta_{\max} \\ |\theta|, & \text{其他} \end{cases} \quad (9)$$

在式(8)和式(9)中,转弯角度定义为连续路径段 $\overrightarrow{W'_{i,j}}$ 与 $\overrightarrow{W'_{i,j+1}}$ 之间,以及 $\overrightarrow{W'_{i,j+1}}$ 与 $\overrightarrow{W'_{i,j+2}}$ 在 O_{xy} 平面上的投影夹角。其中, $\theta_{\max}$ 为无人机最大转弯角度。

$$\phi_{i,j} = \arctan \left(\frac{W_{i,j} - W_{i,j+1}}{\left\| \overrightarrow{W'_{i,j} W'_{i,j+1}} \right\|} \right) \quad (10)$$

$$\phi_{i,j} = \begin{cases} \phi_{\max}, & |\phi_{i,j} - \phi_{i,j-1}| > \phi_{\max} \\ |\phi_{i,j} - \phi_{i,j-1}|, & \text{其他} \end{cases} \quad (11)$$

爬升角定义为连续路径段 $\overrightarrow{W'_{i,j} W'_{i,j+1}}$ 和 $\overrightarrow{W'_{i,j} W'_{i,j+1}}$ 投影至 O_{xy} 平面所形成的夹角。其计算可通过式(10)与式(11)实现,其中 $\phi_{\max}$ 为无人机最大爬升角。成本 C_4 由式(12)表示。

$$C_4 = \sum_{j=1}^{N-2} \theta_{i,j} + \sum_{j=1}^{N-1} \phi_{i,j} \quad (12)$$

(5) 总成本函数

路径长度、威胁规避、高度约束以及转向与爬平滑性4个成本要素通过加权求和进行整合,构建出综合目标函数,该函数同时考虑了轨迹最优性、飞行安全性和可行性约束。最终形成的总成本函数如式(13)所示。

$$C = \sum_{k=1}^4 w_k C_k \quad (13)$$

其中, w_k 表示权重系数。通过上述对每个成本组件的定义,总成本函数得以完全确定,并可作为路径规划过程的输入。

2 所提方法

通过总成本函数可知,无人机路径规划属于典型的高维、多约束、非线性优化问题。复杂地形、威胁规避和路径平滑性等要求使其具有较强的非线性和多峰特征,对算法的全局搜索能力提出了更高要求。尽管DE具有结构简单和优化能力强等优点,但仍存在收敛速度慢、易陷入局部最优等问题。因此,本文从变异策略选择、历史淘汰试用载体复用以及自适应参数控制3个方面对传统DE进行改进,

以提升其在无人机路径规划中的优化性能。

2.1 基于泊松分布的自适应变异策略选择

由于DE算法无法保证子代个体始终获得低于亲代的适应度值,因此引入泊松分布来概率性地估计新生个体获得适应度提升的可能性^[30]。泊松分布描述特定时间或空间区间内随机事件的发生数量,其概率质量函数由式(14)表示^[31]。

$$P(X=k) = \frac{\lambda^k e^{-\lambda}}{k!}, k=0,1,2,\dots \quad (14)$$

其中, λ 表示给定时间段内事件发生的平均次数, k 代表特定的发生次数。

泊松分布通过追踪过去100代中的成功突变数量来估算当前代的突变成功率。具体而言,上一代的成功突变数 sr 被视为观测事件计数,而过去100代的平均成功突变数 R 被视为平均事件率,具体如式(15)所示。

$$P(SR=sr) = \frac{R^{sr} e^{-R}}{sr!} \quad (15)$$

在进化过程中,通过泊松分布预测每代的突变成功率,从而引导突变策略的自适应调整。借助该概率模型,可评估当前代的突变成功率是否可能低于前代。当预测突变成功率较低时,保留原始突变策略以维持探索行为;反之,当预期突变成功率将提升时,则自适应调整突变策略以增强开发能力。对应的数学表达式如式(16)所示。当前至 p -best 单次变异策略具有强探索倾向,可在全局解空间进行大规模搜索。为避免次优方向的过度演化,当预测变异成功率提升时,引入具有显著开发能力的精英引导变异策略。该策略增强局部优化能力,加速收敛至高质量解。通过这种自适应变异策略选择机制,种群在有效开发搜索空间中具有前景区域的同时,仍能保持充分的全局探索能力,从而提高发现全局最优解的可能性。

$$V_{i,G} = \begin{cases} X_{c1} + F \cdot (X_{pbest,G} - X_{i,G}), & P < sr \\ X_{i,G} + F \cdot (X_{pbest,G} - X_{i,G}) + F \cdot (X_{r1,G} - \widetilde{X_{r2,G}}), & \text{其他} \end{cases} \quad (16)$$

其中, $X_{i,G}$ 为当前个体; X_{c1} 为从当前种群中随机选取的两个个体之均值,代表当前种群中不存在的个体; $X_{pbest,G}$ 为从当前种群前11%随机选取的个体; $X_{r1,G}$ 是当前种群中与当前个体不同的随机个体; $\widetilde{X_{r2,G}}$ 是从当前种群与历史淘汰种群组合中随

机选取的个体（历史淘汰个体存储于外部档案库 A ）； F 为缩放因子。

2.2 历史淘汰试用载体复用

在差分进化中，探索与开发之间的有效平衡对提升性能至关重要。当算法识别出有前景的搜索方向时，持续沿此方向开发可显著加速收敛至全局最优解。然而，由于遗传演化过程固有的随机性和不确定性，若仅依赖当前变异操作，种群可能偏离有利搜索方向或陷入局部最优解。为提升搜索效率，系统参照精英个体演化方向评估每个个体的演化方向。当个体演化方向与精英个体演化方向不一致时，将用从历史淘汰试探向量中新生成的候选个体进行替换。该机制在保持种群多样性的同时促进方向一致性，从而增强收敛稳定性与搜索效能。

进化过程中生成的所有个体均被记录以保存历史信息。通过持续更新历史差分向量的均值向量与协方差矩阵，提取协方差矩阵的主特征向量以刻画历史种群的进化方向，记为 S_1 。种群向精英个体演化的方向定义为精英进化方向，记为 S_2 。随后计算 S_1 与 S_2 之间的余弦相似度，如式（17）所示。基于余弦相似度结合停滞指标评估历史演化方向与精英方向的一致性，其中停滞阈值设定为 $T=10$ 。若判定两方向一致，则种群保持不变；否则引入历史淘汰的试验向量作为扰动向量生成新候选个体，从而修正不利的搜索方向。

$$\cos(S_1, S_2) = \frac{S_1 \cdot S_2}{\|S_1\| \cdot \|S_2\|} \quad (17)$$

构建外部档案库（SP）用于存储历史被淘汰的试验向量，以便在后续进化操作中潜在复用。由于被弃用的试验向量保留着与搜索方向相关的宝贵信息，其再利用能更全面地开发整个进化过程中积累的信息。此外，这些被淘汰的试验向量通常分布于搜索空间的不同区域，这有助于后续迭代避免过早收敛于局部最优解，并在算法后期阶段维持种群多样性。生成新个体具体流程如式（18）所示。

$$X_{i,G} = \mathbf{SP}_{r3,G} + F \cdot (X_{\text{pbest},G} - \mathbf{SP}_{r3,G}) + F \cdot (\mathbf{SP}_{r4,G} - \overline{X_{r5,G}}) \quad (18)$$

其中， $\mathbf{SP}_{r3,G}$ 代表从SP中适应度值最高的10%个体中随机选取， $\mathbf{SP}_{r4,G}$ 代表从SP中随机抽取的另一个不同个体， $\overline{X_{r5,G}}$ 指从SP与当前种群的组合集合中随机选取的个体，该个体与 $\mathbf{SP}_{r3,G}$ 、 $\mathbf{SP}_{r4,G}$ 及 $X_{i,G}$ 均不相同。

图3为历史淘汰试用载体复用机制。当当前个体逐渐收敛至局部最优区域时，种群的演化方向容易趋于单一，导致搜索停滞。历史淘汰试用载体中保留了种群先前搜索过程中形成的进化方向信息。通过复用这些向量生成新个体，可以为种群提供新的搜索方向，引导其向潜在更优解区域移动，从而提高种群多样性并增强跳出局部最优解的能力。




图3 历史淘汰试用载体复用机制

2.3 自适应参数控制

在差分进化中，探索与开发之间的有效平衡主要取决于尺度因子 F 和交叉率 CR 的合理设置，这两者决定了亲代种群与子代种群之间的交互作用。固定参数值往往无法适应进化过程不同阶段变化的搜索需求。相比之下，自适应参数方案能在进化过程中动态调整这些值，从而维持高效的搜索行为。此外，在处理多模态优化问题或涉及多样化约束的场景时，自适应参数控制可减轻人工调参需求。该能力使算法能实时自动适应问题特征，从而增强其鲁棒性与通用适用性。

本文算法采用自适应策略调整式（19）中定义的 F 值。在演化初期，赋予 F 较大值以鼓励对解空间的广泛探索，增强全局搜索能力。随着演化进入中期和后期，逐步抑制步长的过度增长，在保持一定全局探索的同时强化局部开发，从而提升收敛精度。类似地，交叉率 CR 根据式（20）进行自适应调节。早期阶段维持较高交叉率，促进亲代与子代个体间显著差异，从而探索搜索空间多样化区域。后期阶段侧重收敛稳定性与局部优化，同时引入微小扰动以维持种群多样性。此设计避免种群内交叉率值趋同，有效降低过早收敛风险。

$$F = \begin{cases} (1 - \mu_f^2) \cdot e^{-\frac{\mu_f^2}{2}} + \varepsilon, & \text{FES} < 0.2 \cdot \text{FES}_{\max} \\ \text{randc}(\mu_f, 0.1), & \text{其他} \end{cases} \quad (19)$$

$$\text{CR} = \begin{cases} \text{randn}(\mu_{\text{cr}}, 0.1) \\ \text{CR} = \begin{cases} \max(0.6, \text{CR}), & \text{FES} < 0.4 \cdot \text{FES}_{\max} \\ \max(0, \min(1, \text{CR})), & \text{其他} \end{cases} \end{cases} \quad (20)$$

其中, FES 为当前评估次数, $\text{FES}_{\max}$ 为最大评估次数。

本文算法融入了源自线性种群规模缩减成功历史自适应差分进化 (L-SHADE) 的自适应历史记忆策略^[32]。该策略记录成功个体对应的 F 值与 CR, 并基于适应度提升采用加权莱默 (Lehmer) 均值进行更新, 从而构建参数记忆池。引入微小扰动项 ε ($\varepsilon = 0.05 \sin(\pi \cdot (\text{rand} - 0.8))$) 以增强参数多样性, 对应公式如式 (21) 所示。随后从该记忆池中采样参数值 μ_f 和 μ_{cr} 用于进化过程。

$$\begin{cases} \Delta f_i = f(\mathbf{X}_{i,G}) - f(\mathbf{U}_{i,G}) \\ w_k = \frac{\Delta f_i}{\sum_{k=1}^{|S|} \Delta f_i} \\ \text{mean}_{\text{WL}}(S) = \frac{\sum_{k=1}^{|S|} w_k \cdot S_k^2}{\sum_{k=1}^{|S|} w_k \cdot S_k} \\ \mu_{k,G+1} = \begin{cases} \text{mean}_{\text{WL}}(S), & S \neq \emptyset \\ \mu_{k,X_{i,G}}, & \text{其他} \end{cases} \end{cases} \quad (21)$$

其中, $f(\mathbf{X}_{i,G})$ 表示目标向量 $\mathbf{X}_{i,G}$ 在第 G 代的适应度值, $f(\mathbf{U}_{i,G})$ 表示试验向量 $\mathbf{U}_{i,G}$ 在第 G 代的适应度值, Δf_i 表示本代第 i 个成功个体适应度的提升量, w_k 代表用于衡量每个成功个体对种群更新贡献的权重系数, S 表示对应成功个体的参数值, $\text{mean}_{\text{WL}}(S)$ 表示加权 Lehmer 均值。

本节阐述了3种不同策略的整合, 并说明它们共同提升算法整体性能的作用。本文算法流程如图4所示, 3种不同策略在进化过程中的协同作用, 促使在全局探索与局部开发之间建立了有效的平衡。

3 实验分析

通过 CEC2017 基准测试套件, 本文在不同复

杂程度的地形场景下, 验证了所提算法在多个问题维度上的有效性。在基于真实数字高程模型 (DEM) 数据构建的仿真环境中开展的实验进一步证明, 相较于多种先进算法, 所提算法整体表现出较强的优化能力, 在多数测试场景中取得了更优结果。

3.1 CEC2017 基准测试套件分析

为全面评估所提算法性能, 实验采用 CEC2017 基准测试套件进行测试^[33]。在多个问题维度 (即 10D、30D、50D 和 100D, 其中 D 表示维度) 上, 将所提算法与多种先进算法进行了比较, 包括 SPSO^[9]、人类进化优化算法 (HEOA)^[34]、基于非线性种群规模缩减的 jSO 差分进化算法 (NLPSR-jSO)^[20]、基于反向学习多样性增强的自适应差分进化算法 (OLBADE)^[21] 和基于多样性增强和新型扰动策略的差分进化算法 (DE-NPS)^[35]。为确保公平比较, 所有算法均分配相同的最大函数评估次数, 设定为 10 000D。此外, 采用非参数威尔科克森秩和检验 (Wilcoxon rank-sum test) 评估比较算法间性能差异的统计显著性。所有算法的详细参数设置见表 1, 其中 c_1 为个体学习因子, c_2 为全局学习因子, ω 为惯性权重, α 为 Logistic 混沌映射控制参数, γ 为 Lévy 飞行分布指数, A 为情境评估阈值, H 为历史参数记忆库的容量, PS 为种群规模, p 为 p-best 个体选择比例, $p_{\min}$ 和 $p_{\max}$ 分别为 p-best 个体选择比例的下限和上限。CEC2017 基准测试套件包含 30 个测试函数, 包括单峰函数 $f_1 \sim f_3$ 、多峰函数 $f_4 \sim f_{10}$ 、混合函数 $f_{11} \sim f_{20}$ 以及组合函数 $f_{21} \sim f_{30}$ 。

表 1 所有算法的推荐参数设置

算法	参数值
SPSO	$c_1 = 1.5, c_2 = 1.5, \omega = 0.98$
HEOA	$\alpha = 4, \gamma = 1.5, A = 0.6$
NLPSR-jSO	$H = 5, \text{PS} = 75D^{2/3}, p_{\min} = 0.0085, p_{\max} = 0.17$
OLBADE	$H = 5, \text{PS} = 25 \lg(D) \sqrt{D} - 4, p = 0.11$
DE-NPS	$H = 5, \text{PS} = 18D - 4, p = 0.11$
所提算法	$H = 5, \text{PS} = 18D - 4, p = 0.11$

CEC2017 基准测试套件涵盖了不同复杂度的优化场景, 可对算法的收敛行为、全局搜索能力、稳定性及鲁棒性进行全面评估。图 5 为在 CEC2017 基准测试套件的 30 维测试条件下, 5 种算法与所提算法之间的性能比较。从图 5 可以看出, 与其他 5 种算法相比较, 所提算法在混合函数 $f_{10} \sim f_{12}$ 、 f_{15} 和 f_{18} 上获得整体优越性能, 其寻优能力较强。




图4 本文算法流程

实验结果表明,在CEC2017基准测试套件的不同问题维度上,所提算法在混合函数上展现了良好的性能优势。这种表现可归因于混合函数独特的阶段依赖性搜索特征,在进化过程中,变异策略具有竞争力。本文引入的泊松分布变异策略选择机制,能根据观测到的成功率动态调节不同变异策略的使用。由此实现搜索资源的更合理分配,使算法在各搜索阶段能保持高效进化。相较于依赖固定或经验确定变异策略的算法,本文算法在混合函数上具有一定优势。不同算法在不同维度下的比较见表2,其中符号“>”“≈”和“<”表示对应比较算法性能优于、约等于和逊于所提算法。由表2可知,与其他5种算法相比较,随着问题维度增加,所提算法整体保持了较好的解质量,并在多数高维测试函数上表现出更强的竞争力。在高维空间中,固定策略与静态参数常难以平衡全局探索与局部开发,导致搜索效率显著下降。相较之下,动态调整变异策略与控制参数可部分缓解维度灾难的负面影

响,从而增强算法在复杂高维环境中的适应性。此外,基于余弦相似性的方向引导机制通过使种群个体与精英个体的进化趋势保持一致,进一步约束了搜索方向。这种方向一致性减少了无效探索和方向性振荡,从而提高了收敛稳定性。这些机制的协同作用使所提算法在高维组合函数上实现了增强的鲁棒性和卓越的整体优化性能。

表2 不同算法在不同维度下的比较

维度	SPSO >/≈/<	HEOA >/≈/<	NLPSR-jSO >/≈/<	OLBADE >/≈/<	DE-NPS >/≈/<
10D	2/2/26	0/0/30	5/14/11	1/25/4	0/25/4
30D	0/0/30	0/0/30	2/15/13	4/16/10	1/20/9
50D	0/0/30	0/0/30	6/12/12	8/11/11	2/17/11
100D	0/0/30	0/0/30	8/7/15	3/12/15	5/13/12

为进一步评估所提算法的演化行为,本文选取了CEC2017基准函数的4种不同类型函数进行阐述,分别是单峰函数的 f_1 、多峰函数的 f_7 、混合函数的 f_{11} 以及组合函数的 f_{21} 。不同类型函数如图6~图9所示,




图5 在CEC2017基准测试套件中的30维测试条件下, 5种算法与所提算法之间的性能比较

收敛曲线的斜率越陡表明该算法的收敛速度越快, 收敛曲线越接近横轴表明该算法越能取到最优值。从图6可以看出, 所提算法在单峰函数 f_1 收敛速度以及找寻最优值上都表现较好; 对于多峰函数 f_7 , 图7展示了本文算法在总体性能上也是有较强的竞争力; 图8呈现出在混合函数 f_{11} 上, 本文算法在寻优能力以及收敛速度上都远远强于其他5种先进算法; 在图9中, 面对组合函数 f_{21} , 本文算法相较于其他5种算法, 整体的性能也能达到较高水平。总体而言, 这些结果表明相较于其他算法, 所提算法在收敛速度和解的质量方面均保持着强劲的竞争力。




图6 f_1 在30维下的比较结果






图7 f_7 在30维下的比较结果

3.2 消融实验

为评估所提3种策略在本文算法中的贡献, 本文设计了3种基于泊松选择与余弦方向引导的自适应参数控制差分进化算法 (APCDE) 变体, 并在CEC2017基准测试套件上进行了评估。由于本文算法主要是在L-SHADE的基础上进行性能上的提升, 因此变体如下。

- (1) V_1 : 用原始L-SHADE设置替换分段参数生成方案, 用于 F 和 CR 参数。
- (2) V_2 : 采用L-SHADE变异策略替代原方案。
- (3) V_3 : 消除余弦相似性, 复用历史淘汰试

图8 f_{11} 在30维下的比较结果图9 f_{21} 在30维下的比较结果

验向量生成新个体。

在 CEC2017 基准测试套件 30 维测试条件下, V_1 、 V_2 、 V_3 与所提算法之间的性能比较如图 10 所示, 标准 APCDE 在 30 个测试函数中优于 V_1 、 V_2 和 V_3 的函数个数分别为 15、11 和 5。

从图 10 可以看出, 分段参数控制机制能够使控制参数在不同搜索阶段进行自适应调整, 从而提升算法对不同类型目标函数的适应能力。混合变异策略有助于优化搜索方向并提高收敛效率。此外, 基于余弦相似性的方向约束结合历史淘汰试验向量复用策略, 在部分测试函数上进一步改善了算法性能, 对维持种群搜索稳定性和提升整体优化能力起到了积极作用。




3.3 无人机路径规划分析

本节实验采用的评估场景基于激光雷达传感器获取的真实 DEM 数据^[36], 无人机飞行过程、威胁区域及起终点均在 MATLAB 环境下进行仿真设置。

所有实验中, 最大迭代次数均设定为 $G_{\max} = 200$, 且每次模拟独立执行 21 次以确保统计可靠性, 对于未能生成可行路径的独立运行, 其目标函数值记为 INF。若某算法全部运行均失败, 则不进行统计检验。由于航点数量 N 直接影响计算效率与路径表示精度, 本文在 4 种不同地形场景下, 针对 $N = 10$ 、20、30 这 3 种航点设置, 对所提算法与其他 5 种算法的性能进行评估比较。模型可视化如图 11~图 14 所示, 环境中的威胁目标以红色圆柱体区域表示。复杂地形特征与多威胁源的存在, 有效验证了算法生成安全最优飞行路径的能力。研究选取 4 种代表性地形类型, 其复杂度各异: 地形 1 相对简单, 以平缓的海拔变化和中等威胁密度为特征; 地形 2 呈现中等复杂度, 威胁在环境中分布相对均匀; 地形 3 具有显著的海拔变化, 对整体路径规划能力提出更高要求; 地形 4 为中高复杂度, 集中分布着高地区域。无人机飞行环境中 4 种地形场景的起始点与目标点坐标见表 3。

不同地形与航点数下 5 种算法与所提算法之间的性能比较见表 4。当 $N = 10$ 时, 所提算法在两种地形中优于 SPSO, 在 3 种地形中优于 HEOA, 在 3 种地形中优于 NLPSR-jSO, 在两种地形中优于 OLBAD, 在 3 种地形中优于 DE-NPS。当 $N = 20$ 时, 该算法在 4 种地形中均优于 SPSO、HEOA、NLPSR-jSO 和 DE-NPS, 并在 3 种地形中优于 OLBAD。当 $N = 30$ 时, 该算法在两种场景中优于 SPSO, 在 4 种场景中优于 HEOA、NLPSR-jSO 以及 DE-NPS, 在两种场景中优于 OLBAD。结果表明, 所提算法在相对平坦地形与显著高差变化环境中能持续识别出总成本更低的高质量路径。此外, 随着航点数量 N 的增加, 所提算法相较于其他 5 种算法的性能优势呈现增长趋势, 进一步验证了其在复杂无人机路径规划场景中的有效性、鲁棒性及适应性。

从图 11~图 14 可以看出, 所提算法在不同地形和航点设置下均能够生成可行飞行路径。相比之下, HEOA 在地形 3 和地形 4 的多个场景中均出现了无法生成可行路径的情况 (表现为 INF/NAN), 表明其在复杂地形环境中的鲁棒性存在不足。与此同时, DE-NPS 在部分相同场景中也出现了 INF/NAN 结果, 进一步说明随着地形复杂度增加, 部分算法难以稳定获得可行解。在不同地形场景与航点设置下, 所提算法均能生成平滑且可行的飞行航迹, 在多数场景中表现出较低的总成本和较好的收

图10 在CEC2017基准测试套件30维测试条件下, V_1 、 V_2 、 V_3 与所提算法之间的性能比较图11 $N=30$ 时地形1模型可视化图12 $N=30$ 时地形2模型可视化



图13 $N=30$ 时地形3模型可视化图14 $N=30$ 时地形4模型可视化

表3 无人机飞行环境中4种地形场景的起始点与目标点坐标

地形序号	起点坐标	终点坐标
1	(149,42,150)	(873,861,150)
2	(167,80,150)	(756,750,150)
3	(33,35,150)	(878,759,150)
4	(55,144,150)	(797,790,150)

敛性能，体现了良好的鲁棒性和综合优化能力。

3.4 计算复杂性分析

所提算法的计算复杂度主要由以下部分构成：初始化、基于泊松分布的变异策略选择机制、选择机制，以及基于余弦相似度的种群多样性维持机制。因此，整体时间复杂度可推导如式(22)所示。

$$\begin{cases} T = T_{\text{init}} + T_{\text{mu}} + T_{\text{sel}} + T_{\text{cos}} \\ T_{\text{init}} = O(\text{PS} \times D) \\ T_{\text{mu}} = O(G \times \text{PS} \times D) \\ T_{\text{sel}} = O(G \times \text{PS} \times \text{fit}) \\ T_{\text{cos}} = O(G \times \text{PS} \times D) \end{cases} \quad (22)$$

其中， T_{init} 表示初始化所需的计算成本， T_{mu} 代表基于泊松分布的变异选择机制的时间复杂度， T_{sel} 是选择操作的计算成本， T_{cos} 表示基于余弦相似

度的种群多样性维护机制的成本， $O(\text{fit})$ 指目标函数评估的成本。因此，总体时间复杂度可表示为 $T = O(\text{PS} \times D) + O(G \times \text{PS} \times D) + O(G \times \text{PS} \times \text{fit}) + O(G \times \text{PS} \times D)$ ，可简化为 $O(G \times \text{PS} \times D)$ 。

4 结束语

本文提出了一种改进的差分进化算法，用于复杂环境中的无人机路径规划。该算法融合了自适应变异策略、基于余弦相似性约束的方向引导机制，以及分阶段自适应参数调整机制。实验结果表明，所提算法在CEC2017基准测试集及无人机路径规划实验中均表现出较强的综合性能。在大多数测试函数和路径规划场景中，所提算法获得了更优的优化结果，并在收敛速度、解质量及鲁棒性方面保持了较强的竞争力。

在混合基准函数和复杂地形场景中展现的良好竞争力表明，所提算法有效平衡了全局探索与局部开发。这种适应性既能高效遍历搜索空间，又可在有前景的区域进行精准优化，从而实现更快收敛与更高质量的解。此外，搜索行为的动态调整增强了算法对过早收敛和环境复杂性的鲁棒性，进一步验证了该算法在解决复杂无人机路径规划问题中的有

表 4 不同地形与航点数下 5 种算法与所提算法之间的性能比较

航点数	地形	SPSO	HEOA	NLPSR-JSO	OLBADE	DE-NPS	所提算法
10N	地形 1	5.518 1×10³/ 1.029 9×10¹(≈)	5.518 1×10 ³ /	5.518 1×10 ³ /	5.518 1×10 ³ /	5.518 1×10 ³ /	5.518 1×10 ³ /
			1.029 9×10 ¹ (≈)	1.029 9×10 ¹ (≈)	1.029 9×10 ¹ (≈)	1.029 9×10 ¹ (≈)	1.029 9×10 ¹
	地形 2	5.080 7×10 ³ /	7.591 7×10 ³ /	6.406 5×10 ³ /	4.993 5×10³/	8.294 6×10 ³ /	5.007 8×10 ³ /
		8.589 6×10 ¹ (<)	4.907 8×10 ² (<)	1.184 9×10 ² (<)	8.795 8×10⁰(>)	4.015 8×10 ² (<)	1.692 7×10 ¹
	地形 3	6.276 9×10 ³ /	INF/NAN(<)	9.173 1×10 ³ /	7.609 1×10 ³ /	INF/NAN(<)	6.182 3×10³/
		1.506 2×10 ² (<)		4.571 0×10 ² (<)	4.227 0×10 ² (<)		2.233 1×10²
	地形 4	5.380 8×10³/	INF/NAN(<)	8.053 8×10 ³ /	7.316 4×10 ³ /	INF/NAN(<)	5.404 9×10 ³ /
		8.825 5×10¹(≈)		6.024 9×10 ² (<)	4.910 3×10 ² (<)		2.567 4×10 ²
20N	地形 1	5.704 7×10 ³ /	1.093 5×10 ⁴ /	7.275 3×10 ³ /	5.556 0×10 ³ /	1.068 2×10 ⁴ /	5.542 2×10³/
		1.956 6×10 ² (<)	2.290 1×10 ³ (<)	2.549 6×10 ² (<)	5.133 9×10 ⁰ (<)	4.799 7×10 ² (<)	8.755 0×10⁰
	地形 2	5.303 6×10 ³ /	1.021 1×10 ⁴ /	7.128 9×10 ³ /	5.040 1×10³/	9.657 5×10 ³ /	5.047 4×10 ³ /
		1.159 5×10 ² (<)	8.809 6×10 ² (<)	2.197 7×10 ² (<)	6.295 3×10⁰(>)	5.670 6×10 ² (<)	5.674 8×10 ⁰
	地形 3	6.968 3×10 ³ /	INF/NAN(<)	1.123 8×10 ⁴ /	9.535 2×10 ³ /	INF/NAN(<)	6.480 6×10³/
		2.710 3×10 ² (<)		8.984 3×10 ² (<)	6.227 1×10 ² (<)		2.409 3×10²
	地形 4	5.883 2×10 ³ /	INF/NAN(<)	1.037 8×10 ⁴ /	9.129 1×10 ³ /	INF/NAN(<)	5.677 6×10³/
		2.466 8×10 ² (<)		8.724 9×10 ² (<)	8.798 7×10 ² (<)		4.999 2×10²
30N	地形 1	5.884 8×10 ³ /	1.595 7×10 ⁴ /	8.022 1×10 ³ /	5.572 1×10³/	1.182 9×10 ⁴ /	5.584 1×10 ³ /
		1.603 8×10 ² (<)	1.484 7×10 ³ (<)	3.408 6×10 ² (<)	1.324 2×10¹(>)	6.563 3×10 ² (<)	1.451 9×10 ¹
	地形 2	5.626 0×10 ³ /	1.302 4×10 ⁴ /	7.745 3×10 ³ /	5.149 2×10³/	1.106 2×10 ⁴ /	5.194 3×10 ³ /
		8.705 0×10 ¹ (<)	1.276 5×10 ³ (<)	2.686 9×10 ² (<)	4.738 0×10¹(>)	5.322 6×10 ² (<)	1.940 9×10 ¹
	地形 3	7.579 2×10³/	INF/NAN(<)	INF/NAN(<)	1.236 8×10 ⁴ /	INF/NAN(<)	7.949 4×10 ³ /
		5.459 7×10²(≈)			1.647 3×10 ³ (<)		2.483 9×10 ³
	地形 4	6.588 8×10³/	INF/NAN(<)	1.272 7×10 ⁴ /	1.110 8×10 ⁴ /	INF/NAN(<)	8.193 0×10 ³ /
		3.245 8×10²(≈)		1.615 9×10 ³ (<)	1.436 3×10 ³ (<)		2.519 3×10 ³
合计	>/≈/<	0/4/8	0/1/11	0/1/11	4/1/7	0/1/11	—

效性和可靠性。后续研究将聚焦于将该算法扩展至动态与不确定环境，通过集成实时障碍规避、多无人机协同控制及节能路径规划策略实现。这些扩展有望进一步提升算法在实际无人机操作中的实用性和鲁棒性。

参考文献:

- [1] Maboudi M, Homaei M, Song S, et al. A review on viewpoints and path planning for UAV-based 3-D reconstruction[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2023, 16: 5026-5048.
- [2] 武子怡, 高晓楠, 朱献超, 等. 基于 KPPO 算法的四旋翼无人机飞行控制[J]. 智能科学与技术学报, 2025, 7(3): 381-395.
Wu Z Y, Gao X N, Zhu X C, et al. Quadrotor UAV flight control based on the KPPO algorithm[J]. Chinese Journal of Intelligent Science and Technology, 2025, 7(3): 381-395.
- [3] Fu Z J, Yu J N, Xie G W, et al. A heuristic evolutionary algorithm of UAV path planning[J]. Wireless Communications and Mobile Computing, 2018, 2018: 2851964.
- [4] Jiang Y, Xu X X, Zheng M Y, et al. Evolutionary computation for unmanned aerial vehicle path planning: a survey[J]. Artificial Intelligence Review, 2024, 57(10): 267.
- [5] 潘宇光. 智能无人机路径规划技术的研究进展与挑战[J]. 计算机测量与控制, 2026, doi: cnki.net/urlid/11.4762.TP.20260529.0835.004.
Pan Y G. Research progress and challenges in intelligent drone path planning technology[J]. Computer Measurement & Control, 2026, doi: cnki.net/urlid/11.4762.TP.20260529.0835.004..
- [6] Li S J, Gong W Y, Wang L, et al. Optimal power flow by means of improved adaptive differential evolution[J]. Energy, 2020, 198: 117314.
- [7] Huang T, Fan K G, Sun W. Density gradient-RRT: an improved rapidly exploring random tree algorithm for UAV path planning[J]. Expert Systems with Applications, 2024, 252: 124121.
- [8] Lyu L X, Yang F. MPPA: a modified marine predator algorithm for 3D UAV path planning in complex environments with multiple threats[J]. Expert Systems with Applications, 2024, 257: 124955.
- [9] Phung M D, Ha Q P. Safety-enhanced UAV path planning with spherical vector-based particle swarm optimization[J]. Applied Soft Computing, 2021, 107: 107376.
- [10] Cao Z J, Xu K, Wang Z Y, et al. An adaptive population size based Differential Evolution by mining historical population similarity for path planning of unmanned aerial vehicles[J]. Information Sciences, 2024, 666: 120432.
- [11] Qin H X, Bai W L, Xiang Y, et al. A self-adaptive collaborative differential evolution algorithm for solving energy resource management problems in smart grids[J]. IEEE Transactions on Evolutionary Computation, 2024, 28(5): 1427-1441.
- [12] 王荣笙, 王晓刚, 龙艺璇, 等. 基于改进差分进化的智能综合评价法[J]. 智能科学与技术学报, 2025, 7(1): 64-76.
Wang R S, Wang X G, Long Y X, et al. An intelligent comprehensive scoring approach based on improved differential evolution algorithm[J]. Chinese Journal of Intelligent Science and Technology, 2025, 7(1): 64-76.
- [13] Bilal, Pant M, Zaheer H, et al. Differential Evolution: a review of more

- than two decades of research[J]. *Engineering Applications of Artificial Intelligence*, 2020, 90: 103479.
- [14] Das S, Suganthan P N. Differential evolution: a survey of the state-of-the-art[J]. *IEEE Transactions on Evolutionary Computation*, 2011, 15(1): 4-31.
- [15] Meng Z Y. Dimension improvements based adaptation of control parameters in Differential Evolution: a fitness-value-independent approach[J]. *Expert Systems with Applications*, 2023, 223: 119848.
- [16] Brest J, Greiner S, Boskovic B, et al. Self-adapting control parameters in differential evolution: a comparative study on numerical benchmark problems[J]. *IEEE Transactions on Evolutionary Computation*, 2006, 10(6): 646-657.
- [17] Qin A K, Suganthan P N. Self-adaptive differential evolution algorithm for numerical optimization[C]//*Proceedings of the 2005 IEEE Congress on Evolutionary Computation*. Piscataway: IEEE Press, 2005: 1785-1791.
- [18] Zhang M H, Han Y H, Chen S Y, et al. A Multi-Strategy Improved Differential Evolution algorithm for UAV 3D trajectory planning in complex mountainous environments[J]. *Engineering Applications of Artificial Intelligence*, 2023, 125: 106672.
- [19] Zhang S X, Liu Y H, Zheng L M, et al. Differential evolution with collective ensemble learning[J]. *Swarm and Evolutionary Computation*, 2024, 87: 101521.
- [20] Zhou B B, Huang Y. An adaptive archive differential evolution with non-linear population size reduction and selective pressure[J]. *Information Sciences*, 2024, 682: 121273.
- [21] Song Z H, Ren C L, Meng Z Y. An adaptive differential evolution with opposition-learning based diversity enhancement[J]. *Expert Systems with Applications*, 2024, 243: 122942.
- [22] Zhang S X, Liu Y H, Hu X R, et al. Differential evolution with dimensionally adaptive inheritance[J]. *Engineering Applications of Artificial Intelligence*, 2026, 163: 112587.
- [23] Luo Z Y, Qian X Z, Song W. Enhanced differential evolution with hierarchical selection mutation and distance-based selection strategy[J]. *Engineering Applications of Artificial Intelligence*, 2025, 144: 110124.
- [24] Chai X Z, Zheng Z S, Xiao J M, et al. Multi-strategy fusion differential evolution algorithm for UAV path planning in complex environment[J]. *Aerospace Science and Technology*, 2022, 121: 107287.
- [25] 董超, 沈赞, 屈毓铎. 基于无人机的边缘智能计算研究综述[J]. *智能科学与技术学报*, 2020, 2(3): 227-239.
- Dong C, Shen Y, Qu Y B. A survey of UAV-based edge intelligent computing[J]. *Chinese Journal of Intelligent Science and Technology*, 2020, 2(3): 227-239.
- [26] Huang C, Zhou X B, Ran X J, et al. Adaptive cylinder vector particle swarm optimization with differential evolution for UAV path planning[J]. *Engineering Applications of Artificial Intelligence*, 2023, 121: 105942.
- [27] 郝晓辰, 冀亚坤, 郑立召, 等. 基于差分进化的水泥烧成系统动态优化算法[J]. *智能科学与技术学报*, 2020, 2(2): 186-193.
- Hao X C, Ji Y K, Zheng L Z, et al. Dynamic optimization algorithm of cement firing system based on differential evolution[J]. *Chinese Journal of Intelligent Science and Technology*, 2020, 2(2): 186-193.
- [28] Jia R H, Li H C, Sun P F, et al. UAV trajectory optimization for visual coverage in mobile networks using matrix-based differential evolution[J]. *Knowledge-Based Systems*, 2025, 324: 113797.
- [29] Yu X B, Jiang N J, Wang X M, et al. A hybrid algorithm based on grey wolf optimizer and differential evolution for UAV path planning[J]. *Expert Systems with Applications*, 2023, 215: 119327.
- [30] Joe H, Zhu R. Generalized Poisson distribution: the property of mixture of Poisson and comparison with negative binomial distribution[J]. *Biometrical Journal*, 2005, 47(2): 219-229.
- [31] Karlis D, Xekalaki E. Mixed Poisson distributions[J]. *International Statistical Review / Revue Internationale de Statistique*, 73(1): 35-58.
- [32] Tanabe R, Fukunaga A S. Improving the search performance of SHADE using linear population size reduction[C]//*Proceedings of the 2014 IEEE Congress on Evolutionary Computation (CEC)*. Piscataway: IEEE Press, 2014: 1658-1665.
- [33] Wu G, Mallipeddi R, Suganthan P N. Problem definitions and evaluation criteria for the CEC 2017 competition on constrained real-parameter optimization[R]. 2017.
- [34] Lian J B, Hui G H. Human evolutionary optimization algorithm[J]. *Expert Systems with Applications*, 2024, 241: 122638.
- [35] Song Z H, Sun L L, Matsveichuk N, et al. Diversity enhancement-based Differential Evolution with a novel perturbation strategy[J]. *Swarm and Evolutionary Computation*, 2025, 92: 101822.
- [36] Shehadeh M A, Kudela J. Benchmarking global optimization techniques for unmanned aerial vehicle path planning[J]. *Expert Systems with Applications*, 2025, 293: 128645.


[作者简介]



陈德旺 (1976-), 男, 福建理工大学计算机与数据科学学院教授, 主要研究方向为人工智能算法、模糊系统、智能交通系统。



陈秀彬 (2001-), 女, 福建理工大学人工智能与交通工程学院硕士生, 主要研究方向为人工智能算法。



孟振宇 (1987-), 男, 福建理工大学计算机与数据科学学院教授, 主要研究方向为人工智能、计算智能。



Bahattin Turetken, 男, 博士, 科贾埃利大学工程学院教授, 主要研究方向为无线通信、信号处理、电子与通信工程。