

基于多策略融合人工旅鼠优化算法的 PID 参数优化

于昊延¹ 赵楠楠^{1*} 武超萱¹ 林嘉怡¹ 欧阳鑫玉¹

YU Haoyan ZHAO Nannan WU Chaoxuan LIN Jiayi OUYANG Xinyu

摘要

PID 控制器广泛应用于工业领域,其参数优化是高效实施的关键问题。文章结合 PID 参数优化,提出一种融合多种搜索策略的改进人工旅鼠算法。该改进算法在初始化阶段引入对立学习策略,以此扩大种群覆盖范围;优化进程中动态调控探索与开发的比率,并结合差分扰动及精英引导机制,增强个体突破局部极值区域的能力。通过利用 CEC2022 基准测试函数开展的对比实验结果表明,该改进方法在求解精度与收敛速度上均优于传统人工旅鼠算法。最后,将该算法应用到 PID 控制器参数优化整定中,进一步验证了其有效性。

关键词

人工旅鼠算法;多策略融合;智能优化算法;自适应搜索;PID 控制

doi: 10.3969/j.issn.1672-9528.2026.04.033

0 引言

在工业过程控制领域,PID 控制器因结构简洁明晰、可靠性高,长期处于主导地位,被广泛应用。然而,PID 控制器参数的调节过程过于依赖人工经验,在应对非线性、时变系统等复杂条件时,难以获得最佳的性能指标。随着科技的发展,近年来,元启发式算法的兴起,为 PID 控制器参数优化提供了很多可行方法,例如这类算法主要是通过模拟生物进化、群体协作或生物的生存策略而形成的智能算法,能够有效解决传统优化算法难以处理的高维、多峰及非线性等问题。典型的元启发式算法包括蜣螂优化算法^[1]、蛇优化算法^[2]、鹰优化算法^[3]、蚁群优化算法^[4]、遗传算法^[5]、粒子群优化算法^[6]和灰狼优化^[7]等。这些算法的优点是结构简单、无需依赖梯度信息、全局搜索能力强,在解决复杂优化问题时体现出优于传统算法适配性和灵活性。

人工旅鼠算法(artificial lemming algorithm, ALA)^[8]是一种模拟旅鼠群体行为的元启发式优化算法。该算法引入 Levy 飞行机制,让算法个体实现长距离跳跃,以增强算法全局搜索能力。与其他优化算法相比,ALA 优势在于参数设置简便、易于编程实现,可应用于多种复杂优化问题的求解。但在实际应用中仍存在局限性:初始种群空间分布相对集中,种群多样性不足,可能导致算法在搜索初期就陷入局部最优区域,难以实现全局寻优;算法在探索与开发的模式转换之间缺乏自适应调节机制,固定的搜索模式会在迭代后期制约

优化性能的提升;同时,ALA 迭代后期个体搜索能力下降,容易陷入局部最优解,难以进一步提高求解质量。

结合 PID 控制器参数优化整定问题,引入人工旅鼠算法,针对其局限性,本文提出了一种融合多种策略的改进人工旅鼠算法(adaptive differential elite-refining artificial lemming algorithm, ADEALA),其改进体现在三个方面:

(1) 引入对立学习策略,在初始化阶段构建个体的边界对立解并择优保留,提高初始种群的多样性;

(2) 采用线性衰减机制对探索概率进行自适应调控^[9],使搜索行为在迭代过程中逐步由全局探索过渡到局部开发,实现探索与开发的动态平衡,进而提升算法的整体寻优效率;

(3) 在优化过程中定期围绕当前最优解执行高斯扰动,生成邻域解以加强局部精细搜索,进一步提高算法求解精度。

为了验证 ADEALA 的效果,本文以 CEC2022 标准测试函数集为基准进行实验验证,对 ADEALA 的性能与 ALA 进行对比分析,结果表明, ADEALA 在收敛速度和求解精度上都有更好的表现。最后,将该改进算法应用到了 PID 控制器参数的优化整定中。

1 人工旅鼠算法

人工旅鼠算法模拟了旅鼠在野外的四种典型行为:长途迁徙、挖洞、觅食和躲避天敌。包括探索与开发两个核心操作,其中长途迁徙与挖洞行为强化了算法的全局探索能力,觅食与躲避天敌行为则强化了较优区域精细化搜索,同时,通过行为扰动能够提升种群多样性,避免算法过早收敛。此外,该算法引入了能量衰减机制去动态调控探索与开发的平衡关系。利用该算法,可以自适应调整行为模式,实现大范围全局搜索和局部精细化搜索,保证了算法的收敛精度与运行稳定性。

1. 辽宁科技大学电子与信息工程学院 辽宁鞍山 114051

[基金项目] 辽宁科技大学 2026 年大学生创新创业训练计划项目

1.1 初始化种群

ALA 为种群型优化算法, 开展迭代寻优前, 需先完成所有搜索代理的位置初始化。所有初始候选解构成一个矩阵, 矩阵维度为 $N \times \text{Dim}$ (N 为种群规模, Dim 为问题维度), 矩阵内各元素取值均限定在优化问题的上下界范围内, 种群初始化公式为:

$$\mathbf{Z} = \begin{bmatrix} \mathbf{Z}_{1,1} & \mathbf{Z}_{1,2} & \cdots & \mathbf{Z}_{1,\text{Dim}-1} & \mathbf{Z}_{1,\text{Dim}} \\ \mathbf{Z}_{2,1} & \mathbf{Z}_{2,2} & \cdots & \mathbf{Z}_{2,\text{Dim}-1} & \mathbf{Z}_{2,\text{Dim}} \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ \mathbf{Z}_{i,1} & \mathbf{Z}_{i,2} & \cdots & \mathbf{Z}_{i,\text{Dim}-1} & \mathbf{Z}_{i,\text{Dim}} \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ \mathbf{Z}_{N-1,1} & \mathbf{Z}_{N-1,2} & \cdots & \mathbf{Z}_{N-1,\text{Dim}-1} & \mathbf{Z}_{N-1,\text{Dim}} \\ \mathbf{Z}_{N,1} & \mathbf{Z}_{N,2} & \cdots & \mathbf{Z}_{N,\text{Dim}-1} & \mathbf{Z}_{N,\text{Dim}} \end{bmatrix} \quad (1)$$

$$\mathbf{Z}_{i,j} = \text{LB}_j + \text{rand} \times (\text{UB}_j - \text{LB}_j), i = 1, 2, \dots, N, j = 1, 2, \dots, \text{Dim} \quad (2)$$

式中: rand 表示 0~1 范围内的随机值; LB_j 表示第 j 维的下限; UB_j 表示第 j 维的上限。

1.2 长距离迁徙 (探索)

长距离迁徙是旅鼠的典型自然行为, 当种群数量过度增长、环境承载能力不足引发食物短缺时, 旅鼠会随机发起长距离迁徙。迁徙过程中, 旅鼠会结合自身当前位置与种群内随机个体的位置探查搜索空间, 以此寻找食物充足的栖息区域, 保障自身生存与种群延续。受生态环境、气候等外部因素影响, 旅鼠迁徙的方向与距离均处于动态变化中, 无固定规律。为精准模拟该行为并适配算法优化需求, 本文构建了对应的数学方程, 实现探索与开发的动态平衡, 进而提升算法的整体寻优效率。用公式表示为:

$$\mathbf{Z}_i(t+1) = \mathbf{Z}_{\text{best}}(t) + F \times \mathbf{B} \times (\mathbf{R} \times (\mathbf{Z}_{\text{best}}(t) - \mathbf{Z}_i(t)) + (1 - \mathbf{R}) \times (\mathbf{Z}_i(t) - \mathbf{Z}_a(t))) \quad (3)$$

式中: $\mathbf{Z}_i(t+1)$ 表示第 i 个搜索代理在第 $(t+1)$ 次迭代时的位置; $\mathbf{Z}_{\text{best}}(t+1)$ 表示当前最优解; F 表示改变搜索方向的标志; $\mathbf{B}$ 表示布朗运动的随机数向量, 通过均匀步长, 对搜索空间内各类潜在最优区域进行全面探查。

标准布朗运动的步长是通过方差为 1、均值为 0 的正态分布的概率密度函数得到的, 用公式表示为:

$$f_{\text{BM}}(x; 0, 1) = \frac{1}{\sqrt{2\pi}} \times \exp\left(-\frac{x^2}{2}\right) \quad (4)$$

$$F = \begin{cases} 1, & \text{if } [2 \times \text{rand} + 1] = 1 \\ -1, & \text{if } [2 \times \text{rand} + 1] = 2 \end{cases} \quad (5)$$

$$\mathbf{R} = 2 \times \text{RAND}(1, \text{Dim}) - 1 \quad (6)$$

式中: $\mathbf{R}$ 为一个大小为 $1 \times \text{Dim}$ 的向量, 是区间 $[-1, 1]$ 中均匀分布的随机数, 该向量控制种群中当前最优个体和随机个体的移动轨迹, 用于表示旅鼠迁徙过程中个体间的相互作用关系。

1.3 挖洞 (探索)

挖洞是旅鼠的另一核心自然行为, 旅鼠会在栖息地挖掘洞穴, 构建出结构复杂的隧道系统。这类隧道拥有双重功能, 既是旅鼠躲避天敌、保障自身安全的庇护所, 也是其储存食物、应对食物短缺的储藏空间。旅鼠挖掘新洞穴并非盲目开展, 而是结合自身当前洞穴与种群内随机个体的洞穴位置, 随机进行挖掘。该行为模式可帮助旅鼠快速躲避天敌追捕, 提升食物搜寻效率, 使其更好地适应野外的生存环境, 同时为算法的全局探索环节提供了自然行为参考。

$$\mathbf{Z}_i(t+1) = \mathbf{Z}_i(t) + F \times L \times (\mathbf{Z}_{\text{best}}(t) - \mathbf{Z}_b(t)) \quad (7)$$

式中: L 表示与当前迭代次数相关的随机数; i 表示从总体中随机选取的搜索个体; b 表示 1 和 N 之间的随机整数索引值。 L 和 $\mathbf{Z}_b(t)$ 表示描述旅鼠个体在挖掘新洞穴时的相互作用。 L 的值计算公式为:

$$L = \text{rand} \times \left(1 + \sin\left(\frac{t}{2}\right)\right) \quad (8)$$

1.4 觅食 (开发)

觅食是旅鼠在资源丰富的区域进行随机游荡、四处探寻食物资源的行为, 这个特征使算法侧重于局部精细化搜索, 有利于实现探索与开发的动态平衡。觅食行为通过向当前最优解附近微调位置来提高收敛精度, 进而提升算法的整体寻优效率。

$$\mathbf{Z}_i(t+1) = \mathbf{Z}_{\text{best}}(t) + F \times \text{spiral} \times \text{rand} \times \mathbf{Z}_i(t) \quad (9)$$

式中: spiral 表示觅食期间随机搜索的螺旋形状。

$$\text{spiral} = \text{radius} \times (\sin(2 \times \pi \times \text{rand}) + \cos(2 \times \pi \times \text{rand})) \quad (10)$$

式中: radius 表示觅食范围的半径, 具体数值用公式表示为:

$$\text{radius} = \sqrt{\sum_{j=1}^{\text{Dim}} (\mathbf{Z}_{\text{best}, j}(t) - \mathbf{Z}_{i, j}(t))^2} \quad (11)$$

1.5 躲避天敌 (开发)

洞穴是旅鼠的主要避难场所, 旅鼠一旦察觉天敌靠近, 它就会迅速返回到洞穴, 并使用欺骗性动作去干扰天敌的判断, 以此躲避天敌的追捕、提升自身的生存概率。在 ALA 算法中, 这一步主要是模拟旅鼠遭遇天敌时的这种逃逸行为, 并引入随机扰动机制以增强算法跳出局部最优的能力。数学表达中常结合莱维飞行 (Levy flight) 实现非均匀跳跃, 提升算法的整体寻优效率。

$$\mathbf{Z}_i(t+1) = \mathbf{Z}_{\text{best}}(t) + F \times G \times \text{Levy}(\text{Dim}) \times (\mathbf{Z}_{\text{best}}(t) - \mathbf{Z}_i(t)) \quad (12)$$

$$G = 2 \times \left(1 - \frac{t}{T_{\text{max}}}\right) \quad (13)$$

式中: G 表示旅鼠的逃逸能力, 其数值随着迭代次数的增加而降低; T_{max} 表示最大迭代次数, 用于控制逃逸系数的衰减幅度, 确保逃逸行为贴合算法迭代规律; $\text{Levy}(x)$ 表示莱维飞

行函数,用来模拟旅鼠在逃跑时的欺骗性动作。

莱维飞行函数用公式表示为:

$$\text{Levy}(x) = 0.01 \times \frac{\mu \times \sigma}{|v|^{\frac{1}{\beta}}}, \sigma = \left(\frac{\Gamma(1+\beta) \times \sin\left(\frac{\pi\beta}{2}\right)}{\Gamma\left(\frac{1+\beta}{2}\right) \times \beta \times 2^{\frac{\beta-1}{2}}} \right)^{\frac{1}{\beta}} \quad (14)$$

式中: μ 和 v 表示 0~1 区间内的随机值; $\beta=1.5$ 。

2 增加的多策略

2.1 自适应探索与开发平衡机制

为提升算法在复杂搜索空间中的性能,本算法采取了动态调节全局搜索与局部搜索权重的策略^[10]。具体而言,当连续多代中全局最优值的提升幅度较小,说明算法可能陷入局部极值,此时增加全局性搜索(例如 Levy 飞行)的概率,以提升算法摆脱局部极值的能力;反之,若全局最优解的提升较为显著,就着重强化局部搜索,推动算法更快地向最优解逼近。这种机制使得算法能够依据实际的进化情况灵活地调整搜索策略,从而提升整体的寻优效率。

$$\Delta_t = |f_{\text{best}}(t) - f_{\text{best}}(t-k)| \quad (15)$$

式中: $f_{\text{best}}(t)$ 表示第 t 代的全局最优适应度; k 表示窗口宽度取 5。

$$P_{\text{Levy}} = \begin{cases} P_{\text{Levy}}^{\text{high}}, & \Delta_t \geq \epsilon \\ P_{\text{Levy}}^{\text{low}}, & \Delta_t < \epsilon \end{cases} \quad (16)$$

2.2 差分扰动引导策略

在算法主搜索机制基础上,增加了一种差分扰动算子。具体实现为:每代针对个体,随机选取种群中的三个个体,通过差分变异产生新解,并与主算法生成的解以一定比例融合。此方法借鉴了微分进化思想,可以在算法运行过程中持续为种群引入新的搜索方向,有效提升种群的多样性和全局搜索能力。

$$X_i^{\text{DE}} = X_{r1} + F \cdot (X_{r2} - X_{r3}) \quad (17)$$

$$X_i^{\text{new}} = \lambda X_i^{\text{ALA}} + (1-\lambda) X_i^{\text{DE}} \quad (18)$$

式中: X_{r1} 、 X_{r2} 、 X_{r3} 为种群中随机选择的个体; F 为差分缩放因子(通常为 0.5); λ 为权重(依据收敛速度自适应变化); X_i^{ALA} 为主旅鼠算法生成的新位置。

2.3 局部收缩与精英引导机制

为加快算法收敛速度,同时避免低质量个体干扰整体优化效果造成干扰,ADEALA 算法设置了周期性精英引导操作。具体而言,每间隔若干迭代代次,将部分表现较差的个体重新部署至当前最优解附近,并施加微小扰动。该操作能够充分利用当前最优解的相关信息,提升种群整体质量,同时推动算法快速向全局最优解逼近。

$$X_j^{\text{elite}} = X^* + \delta \cdot (\text{rand}() - 0.5) \odot (\text{ub-lb}) \quad (19)$$

式中: X^* 为全局最优个体; δ 为缩放系数(如 0.1); $\odot$ 为 Hadamard 积(逐元素乘法)。

3 仿真实验

本实验采用 CEC2022 测试函数集作为算法性能评价基准。实验设置优化问题为 10 维,变量取值范围限定在 $[-100,100]$ 。每种算法在每个测试函数上独立运行 30 次,并分别记录每组实验的平均值、标准差、最大值、最小值以及中位数。此外,实验还绘制了算法在迭代过程中的平均收敛曲线,以便对搜索效率与结果稳定性进行直观比较。我们挑选了一些典型测试函数,将两种算法的收敛曲线放在一起进行了比较(如图 1~3 所示)。




图 1 F_3 函数收敛曲线




图 2 F_5 函数收敛曲线




图 3 F_{10} 函数收敛曲线

4 PID 控制器参数优化实验

为验证改进算法在实际工程问题中的应用价值，本文将用于 PID 控制器参数的优化设计，并与常规整定方法进行了对比。实验对象选用典型二阶系统。采用的被控对象为：

$$G(s)=\frac{1}{s^2+10s+15}$$
 (20)

以 ITAE 指标作为性能评价准则，常规整定方法得到的典型 PID 控制器参数为：比例系数 $K_p=1$ 、积分系数 $K_i=1$ 、微分系数 $K_d=0$ ，对应的系统性能指标值为 287.127 4；通过 ADEALA 算法优化后得到的 PID 控制器参数为： $K_p=0.1$ 、 $K_i=2$ 、 $K_d=0.982\ 56$ ，此时系统性能指标值优化至 78.884 7，指标降幅显著。对比结果如图 4 所示，ADEALA 优化后的系统阶跃响应在上升速度和系统性能方面均优于传统 PID；图 5 也表明算法具有良好的寻优能力。这充分说明了智能优化方法在复杂对象参数整定中的优势。




图 4 不同算法的系统阶跃响应对比




图 5 ADEALA 优化收敛曲线

5 结论

本文针对人工旅鼠算法在多样性、全局搜索能力和易陷入局部最优等方面的不足，提出了一种多策略改进算法。实验结果表明，ADEALA 在多种标准测试函数和 PID 控制器参

数优化问题中均表现出更高的优化精度和更快的收敛速度。后续研究可进一步拓展该算法在高维、多目标及实际复杂工程优化中的应用。

参考文献：

[1] 朱国庆, 韩东颖, 米振涛, 等. 多策略改进的蜣螂优化算法及其工程实例应用 [J]. 电子测量技术, 2024, 47(21): 82-99.

[2] HASHIM F A, HUSSIEN A G. Snake optimizer: a novel meta-heuristic optimization algorithm [J]. Knowledge-based systems, 2022, 242: 108320.

[3] SHEHAB M, MASHAL I, MOMANI Z, et al. Harris hawks optimization algorithm: variants and applications [J]. Archives of computational methods in engineering, 2022, 29: 5579-5603.

[4] BLUM C. Ant colony optimization: a bibliometric review [J]. Physics of life reviews, 2024, 51: 87-95.

[5] ALHIJAWI B, AWAJAN A. Genetic algorithms: theory, genetic operators, solutions, and applications [J]. Evolutionary intelligence, 2024, 17: 1245-1256.

[6] TIJJANI S, AB WAHAB M N, NOOR M H M. An enhanced particle swarm optimization with position update for optimal feature selection [J]. Expert systems with applications, 2024, 247: 123337.

[7] MAKHADMEH S N, AL-BETAR M A, DOUSH I A, et al. Recent advances in grey wolf optimizer, its versions and applications [J]. IEEE access, 2023, 12: 22991-23028.

[8] XIAO Y N, CUI H, KHURMA R A, et al. Artificial lemming algorithm: a novel bionic meta-heuristic technique for solving real-world engineering optimization problems [J/OL]. Artificial intelligence review, 2025[2026-03-26].<https://link.springer.com/article/10.1007/s10462-024-11023-7>.

[9] HOLLAND J H. Adaptation in natural and artificial systems [M]. Ann Arbor: University of Michigan Press, 1975.

[10] 刘景森, 高赛男, 李煜, 等. 自适应动态分级平衡优化器算法及收敛性 [J]. 浙江大学学报 (工学版), 2025, 59(11): 2389-2399.

【作者简介】

于昊延 (2004—), 男, 辽宁辽阳人, 在读本科, 研究方向: 智能控制。

赵楠楠 (1975—), 通信作者 (email: zhaonannan@ustl.edu.cn), 女, 四川广安人, 博士, 教授、博士生导师, 研究方向: 智能控制、机器学习。

(收稿日期: 2026-02-25 修回日期: 2026-04-01)