

# 基于精英引导自适应差分协同小龙虾优化算法

张佳晨<sup>1</sup>, 王宇轩<sup>1</sup>, 丁超<sup>1</sup>, 李阳<sup>2</sup>, 徐进成<sup>1</sup>, 孔维宾<sup>1\*</sup>

<sup>1</sup>盐城工学院信息工程学院, 江苏 盐城

<sup>2</sup>盐城工学院优培学院, 江苏 盐城

收稿日期: 2026年4月3日; 录用日期: 2026年6月17日; 发布日期: 2026年6月26日

## 摘要

针对传统小龙虾优化算法(Crayfish Optimization Algorithm, COA)存在易早熟收敛、全局勘探与局部开发能力失衡、寻优精度不足等固有缺陷, 本文提出一种基于精英引导自适应差分协同小龙虾优化算法(Elite-Guided Adaptive Differential Cooperative Crayfish Optimization Algorithm, EGCOA)。该算法首先采用精英反向学习机制完成种群初始化, 提升初始解在解空间的分布均匀性与种群多样性, 为算法寻优奠定优质起点; 其次引入融合差分进化的繁殖策略实现个体位置迭代更新, 同步兼顾算法的全局搜索速率与求解精度; 最后提出带自适应扰动的精英保留策略, 有效增强算法的局部深度开发能力, 规避迭代过程中的早熟收敛问题。基于CEC2020基准测试函数集的仿真对比实验结果表明, 所提EGCOA在收敛速度、寻优精度与运行鲁棒性上均显著优于原始COA及其他主流群智能优化算法, 有效解决了原始算法的固有缺陷, 具备更优异的综合优化性能。

## 关键词

小龙虾优化算法, 精英反向学习, 差分进化, 精英保留

# Elite-Guided Adaptive Differential Cooperative Crayfish Optimization Algorithm

Jiachen Zhang<sup>1</sup>, Yuxuan Wang<sup>1</sup>, Chao Ding<sup>1</sup>, Yang Li<sup>2</sup>, Jincheng Xu<sup>1</sup>, Weibin Kong<sup>1\*</sup>

<sup>1</sup>School of Information Engineering, Yancheng Institute of Technology, Yancheng Jiangsu

<sup>2</sup>Youpei College, Yancheng Institute of Technology, Yancheng Jiangsu

Received: April 3, 2026; accepted: June 17, 2026; published: June 26, 2026

\*通讯作者。

文章引用: 张佳晨, 王宇轩, 丁超, 李阳, 徐进成, 孔维宾. 基于精英引导自适应差分协同小龙虾优化算法[J]. 软件工程与应用, 2026, 15(3): 404-411. DOI: 10.12677/sea.2026.153038

## Abstract

The Crayfish Optimization Algorithm (COA) suffers from three inherent drawbacks. It tends to converge prematurely, faces an imbalance between global exploration and local exploitation, and exhibits unsatisfactory optimization accuracy. To solve these problems, this paper proposes a Elite-Guided Adaptive Differential Cooperative Crayfish Optimization Algorithm (EGCOA). First, the algorithm adopts an elite opposition-based learning mechanism for population initialization. This mechanism improves the uniform distribution of initial solutions in the solution space and enriches population diversity, laying a high-quality starting point for the optimization process. Second, a breeding strategy integrated with differential evolution (DE) is introduced to update individual positions iteratively. This strategy balances the global search speed and solution accuracy of the algorithm simultaneously. Finally, an elite retention strategy with adaptive perturbation is designed. It effectively enhances the algorithm's local deep exploitation capability, and avoids premature convergence during the iteration process. We carried out simulation comparison experiments based on the CEC2020 benchmark test function suite. The results show that the proposed EGCOA significantly outperforms the original COA and other mainstream swarm intelligence optimization algorithms in convergence speed, optimization accuracy, and operational robustness. It effectively overcomes the inherent defects of the original algorithm, and presents more excellent comprehensive optimization performance.

## Keywords

Crayfish Optimization Algorithm, Elite Opposition-Based Learning, Differential Evolution, Elite Preservation

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

群智能优化算法[1]现已成为研究的热点,其具有鲁棒性强、寻优效率高等优势。近年来,许多新型元启发式算法被提出,用以求解各类复杂优化问题。Jia 等人[2]受到小龙虾的生存行为,提出了一种新的元启发式优化算法,命名为小龙虾优化算法(COA)。该算法与哈里斯鹰优化算法(HHO) [3]、麻雀搜索算法(SSA) [4]等经典智能优化算法相比,COA 在求解稳定性与鲁棒性上表现出更为突出的性能。但从算法运行机制及实验结果分析,原始小龙虾优化算法仍存在易陷入局部最优、勘测精度较低等问题。国内外学者针对该算法的不足,提出了一系列针对性的改进策略。易锌鑫等人[5]采用 Tent-Logistic-Cosine 混沌映射优化 COA 种群初始化,引入非线性收敛因子加快算法收敛,通过环境随机指向机制提升全局搜索能力,并将改进算法与 Otsu 法融合,完成了植物病害图像的高精度分割。徐勇等人[6]则利用 Logistic-tent 混沌映射完成种群初始位置的布设,通过即时信息同步反向学习机制更新个体位置,并采用 Nelder-Mead 单纯形法对最优位置施加扰动,有效增强了算法的局部开发能力,显著提升了算法整体性能。

针对上述不足,本文提出一种基于精英引导自适应差分协同小龙虾优化算法(Multi-Strategy Collaborative Improved Crayfish Optimization Algorithm, EGCOA)。该算法在保留原始 COA 核心搜索框架的前提下,引入精英反向学习初始化机制、融合差分进化的繁殖策略以及精英保留机制,构建了“前期稳定勘探 - 中期快速收敛 - 后期精细开发”的分层协同优化架构,有效改善了传统 COA 的缺陷。

为验证所提算法的有效性, 本文选取 CEC2020 基准测试函数集开展仿真实验, 对改进算法与原始 COA 进行系统性对比分析。结果表明, 所提 EGCOA 在各类测试问题上均具备优异的优化性能, 尤其在算法中后期收敛效率及复杂问题求解能力上优势更为显著。

## 2. 基于精英引导自适应差分协同小龙虾优化算法(EGCOA)

### 2.1. 精英反向学习机制

传统 COA 通过式(1)完成种群初始化, 生成的初始候选解直接决定算法的寻优起点, 进而对其收敛能力与寻优性能产生关键影响。该随机初始化方式生成的个体位置矢量具有强随机性与盲目性, 难以保证初始种群在解空间内的均匀遍历分布。这不仅会增加算法寻优过程的迭代耗时、降低整体寻优效率, 还易加剧算法早熟收敛、陷入局部最优的风险。

$$x_i = lb + rand \times (ub - lb) \quad (1)$$

为解决传统 COA 随机初始化带来的种群分布不均、多样性不足、全局勘探能力受限等问题, 本文引入精英反向学习策略, 通过生成反向解拓展解空间的搜索范围, 提升初始种群多样性, 进而增强算法的全局寻优能力。该策略首先基于(1)随机生成初始种群的原始解, 筛选出其中适应度值最优的前 50% 个体作为精英个体, 再通过反向学习机制[7]生成对应精英个体的反向解, 反向解的计算公式如下:

$$x'_i = lb_i + ub_i - x_i \quad (2)$$

在此基础上, 将生成的反向解与种群内对应个体的原始解进行适应度值对比, 若反向解的适应度表现更优, 则替换对应原始解完成种群更新。该策略可精准筛选并留存优质精英个体, 有效削弱随机初始化带来的种群分布不均、解空间遍历性不足等问题, 显著提升初始种群的整体质量, 进而加快算法的收敛进程。具体实现方式如下:

$$x_i = \begin{cases} x'_i, & fit(x'_i) < fit(x_i) \\ x_i, & \text{others} \end{cases} \quad (3)$$

其中,  $x_i$  代表第  $i$  个小龙虾个体的初始化位置矢量,  $fit(\cdot)$  是用于对个体进行适应度求解的函数。

### 2.2. 融合差分进化的繁殖策略

为进一步提升算法的收敛速度与寻优效率, 本文针对差分进化框架下含双差分向量的经典“current-to-best/1”变异策略[8]进行优化改进, 并将改进后的变异策略融入原始 COA 的个体位置更新环节。精英群落由适应度最优的前 10% 的个体以及他们的平均位置组成, 记为  $X_{elite}$ 。在精英群落中以等概率随机选取个体作为变异基矢量记为  $X_{best}$ , 通过变异操作生成子代个体, 对应的数学表达式如下所示:

$$X_i^{t+1} = X_i^t + F(X_{best} - X_i^t) + F(x_{r1}^t - x_{r2}^t) \quad (4)$$

其中,  $t$  和  $T$  分别是当前迭代次数和最大迭代次数。  $F$  为缩放因子, 用于控制偏差的放大作用, 取值范围为  $[0, 2]$  由下式定义:

$$F = F_0 \times 2^{\lambda(t)} \quad (5)$$

其中,  $F_0$  是缩放因子的初始值, 经测试  $F_0 = 0.5$  是较好的初始值。  $\lambda(t)$  是非线性自适应递减因子, 定义式如下所示:

$$\lambda(t) = \exp\left(1 - \frac{T}{T+1-t}\right) \quad (6)$$

本文基于温度因子调控小龙虾不同行为阶段的基本思想,并通过温度变化实现各阶段的自适应切换。具体行为选择机制如图 1 所示。温度因子定义如下:

$$temp = rand * 15 + 20 \quad (7)$$

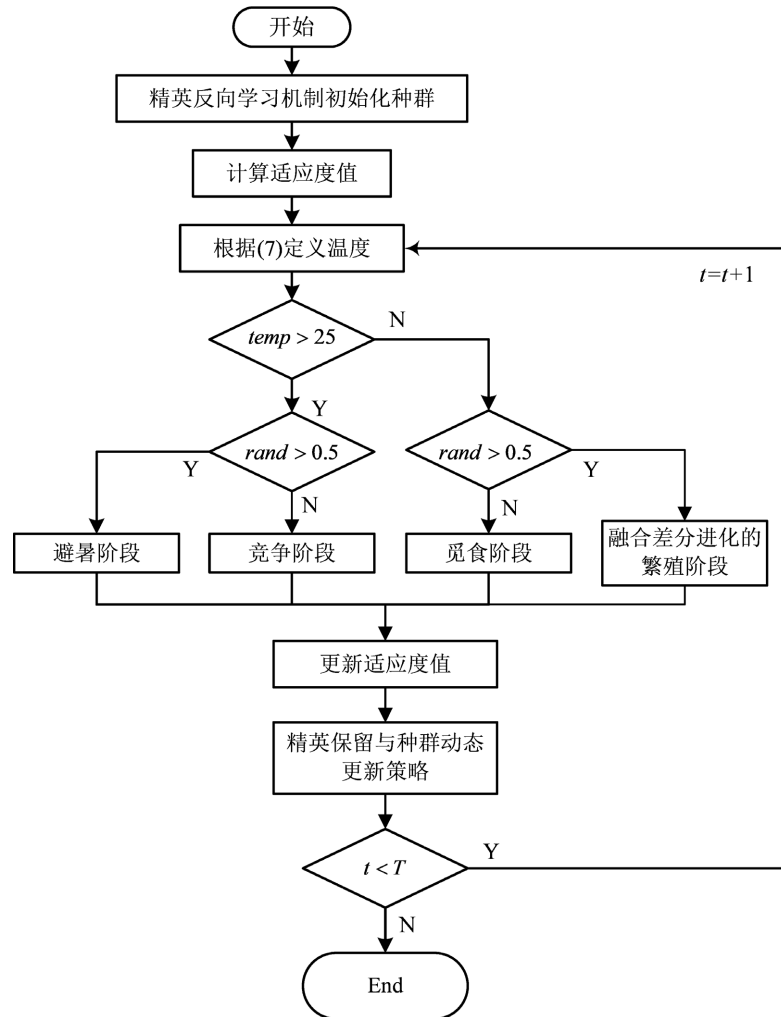


Figure 1. Flowchart of the EGCOA algorithm

图 1. EGCOA 算法流程图

### 2.3. 精英保留与种群动态更新策略

为进一步增强算法迭代中后期在最优解邻域的深度开发能力,加快种群向优质解区域的聚集收敛,同时避免种群多样性快速流失,本文提出一种精英引导的劣势个体择优更新策略。在每一轮迭代过程中,筛选出当前种群内适应度表现最差的 10% 个体进行定向更新。用于替换的新个体基于当前精英种群的优质个体与原劣势个体融合生成,而非采用传统的直接截断替换方式。与简单截断法相比,该更新方式可完整保留原始种群的搜索方向信息,在强化算法局部开发能力的同时,有效维持种群多样性,规避算法早熟收敛的风险。该策略的更新公式如下所示:

$$X_i^{t+1} = \frac{X_{weak}^t + X_{best}^t + \lambda(t)}{2} \quad (8)$$

其中,  $\lambda(t)$  是非线性自适应递减因子, 定义式如(6)所示。  $X_{weak}$  是种群中适应度差的个体位置,  $X_{best}$  是在精英群落中以等概率随机选取个体位置。  $\lambda(t)$  在迭代初期保持较大取值, 有利于增强种群多样性并提高全局勘探能力; 随着迭代次数增加, 其取值非线性减小, 使算法逐步由全局搜索过渡到局部开发; 在迭代后期, 参数快速衰减, 可有效降低随机扰动对优势解收敛的影响, 从而提升寻优精度与收敛稳定性。

COA 在初始化阶段采用随机生成种群的方式, 容易导致初始解分布不均。在中期迭代过程中, 虽然能够借助温度调控在不同行为阶段之间切换, 但个体更新对群体差分信息利用不足, 限制了搜索效率与寻优精度。在后期收敛阶段, 种群逐渐向当前优势区域集中, 探索能力减弱, 易出现早熟收敛现象。针对上述问题, 引入精英反向学习机制以提升初始种群质量, 融合差分进化的繁殖策略以增强个体更新阶段的搜索能力, 并设计带自适应扰动的精英保留策略以维持后期种群活性。

### 3. 仿真结果及分析

本研究的仿真实验在 Windows 11 (64 bit)操作系统及 Matlab R2023b 平台上开展, 选取小龙虾优化算法(COA)、麻雀搜索算法(SSA)、哈里斯鹰优化算法(HHO)作为对比算法, 与所提改进算法 EGCOA 进行性能对比分析。实验严格遵循控制变量原则开展, 所有参与测试的算法均采用统一的参数配置: 种群规模设置为 30, 搜索维度固定为 15, 最大迭代次数统一为 500 次。针对每一个测试函数, 各算法均独立重复运行 30 次, 以规避单次运行的随机波动对实验结果的干扰。实验过程中同步记录寻优结果, 经过数据分析得出最优值、平均值及标准差三项核心指标, 为后续算法收敛性能、寻优精度与鲁棒性的系统分析提供可靠的量化数据支撑。

#### 3.1. 测试函数的选取

为验证 EGCOA 算法的有效性与鲁棒性, 本文选取 CEC2020 基准测试函数集开展实验验证。本文选取其中 7 个典型标准函数进行结果展示, 具体包括单峰函数 F1, 基准函数 F3、F4, 混合函数 F6、F7, 组合函数 F8、F10。上述函数覆盖了不同类型的优化问题特征, 可全面反映算法在不同复杂度场景下的优化性能, 各函数的详细信息详见表 1。

**Table 1.** Overview of CEC2020 benchmark test functions

**表 1.** CEC2020 基准测试函数概况

函数	函数名	特征	最优值
$f_1$	Shifted and Rotated Bent Cigar Function	Unimodal Function	100
$f_3$	Shifted and Rotated Lunacek bi-Rastrigin function	Basic Functions	700
$f_4$	Expanded Rosenbrock's plus Griewangk's function		1900
$f_6$	Hybrid function 2 ( $N=4$ )	Hybrid Functions	1600
$f_7$	Hybrid function 3 ( $N=5$ )		2100
$f_8$	Composition function 1 ( $N=3$ )	Composition Functions	2200
$f_{10}$	Composition function 3 ( $N=5$ )		2500

#### 3.2. 实验结果与分析

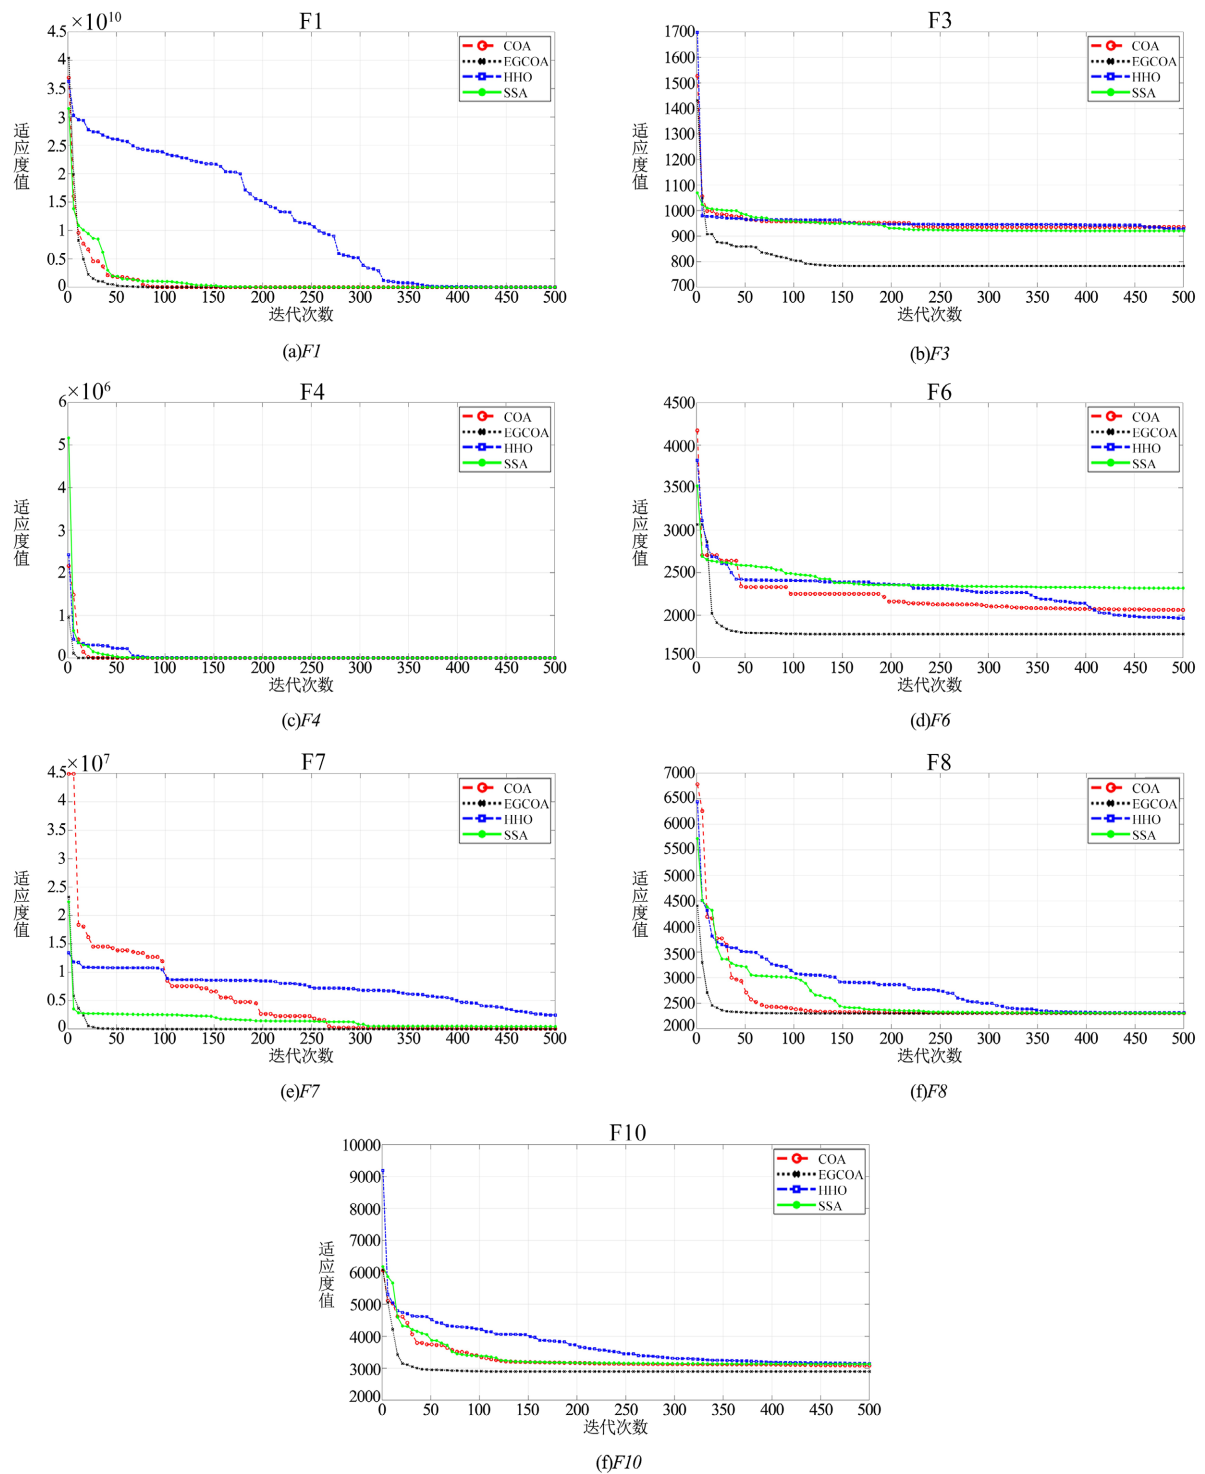
为系统性地验证所提 EGCOA 的综合优化性能, 本文选取原始小龙虾优化算法(COA)、麻雀搜索算法(SSA)、哈里斯鹰优化算法(HHO)三种算法作为对比, 开展同条件下的性能对照实验。各算法的测试统计结果详见表 2。

**Table 2.** Performance metrics under CEC2020 benchmark test functions  
**表 2.** CEC2020 基准测试函数下的性能指标

函数	指标	COA	EGCOA	HHO	SSA
$f_1$	平均值	4.3643e+04	2.9295e+02	5.8782e+06	8.1406e+04
	标准差	2.6873e+04	1.4834e+02	4.5228e+06	7.8464e+04
	最优值	1.3611e+04	1.1248e+02	2.9107e+06	1.5456e+06
$f_3$	平均值	8.6187e+02	7.3641e+02	8.8246e+02	9.1624e+02
	标准差	5.2828E+01	6.1260E+00	3.7642E+01	2.9744E+01
	最优值	7.5557E+02	7.2695E+02	8.0917E+02	8.1827E+02
$f_4$	平均值	1.9088e+03	1.9021e+03	1.9228e+03	1.9146e+03
	标准差	3.5660E+00	5.3596E-01	1.0318E+01	7.1423E+00
	最优值	1.9134E+03	1.9012E+03	1.9119E+03	1.9136E+03
$f_6$	平均值	1.9677e+03	1.7772e+03	2.0818e+03	2.1742e+03
	标准差	1.2565E+02	8.0444E+01	2.2410E+02	2.0606E+02
	最优值	1.7526E+03	1.6151E+03	1.6926E+03	1.6275E+03
$f_7$	平均值	1.5996e+05	2.3106e+03	8.3358e+05	3.8951e+05
	标准差	1.2650e+05	1.1346e+02	7.5636e+05	5.2399e+05
	最优值	5.0005E+03	2.1161E+03	3.0822E+04	3.0782E+03
$f_8$	平均值	2.4700e+03	2.3011e+03	2.5020e+03	2.9157e+03
	标准差	6.3007E+02	5.4159E-01	5.2762E+02	9.5507E+02
	最优值	2.3697E+03	2.3000E+03	2.2725E+03	2.3014E+03
$f_{10}$	平均值	3.0476e+03	2.9200e+03	3.1270e+03	3.0660e+03
	标准差	9.4042E+01	5.3518E+01	5.8818E+01	8.9478E+01
	最优值	2.9081E+03	2.9000+03	2.9435E+03	2.9161E+03

从统计结果可以看出, 所提 EGCOA 在全部 7 个测试函数上的寻优结果, 均能更精准地逼近函数理论最优值, 整体寻优精度显著优于各对比算法。其中, 针对单峰测试函数 F1, EGCOA 的寻优精度相较原始 COA 提升了两个数量级, 这表明 EGCOA 的寻优能力明显优于 COA, 算法改进策略有效。标准差是衡量算法运行鲁棒性的核心指标, 其数值越小, 代表算法在重复实验中的结果波动越小、可靠性越强。实验数据显示, EGCOA 在所有测试函数上的标准差均低于原始 COA 与其余对比算法, 说明本文提出的多策略协同优化框架, 可有效提升算法在复杂优化问题求解过程中的运行稳定性与鲁棒性。

收敛曲线可直观呈现算法迭代全过程的寻优趋势、收敛速率与最终收敛精度, 是算法性能可视化对比的核心依据。本文选取典型测试函数的寻优过程, 绘制了 EGCOA 与 3 种对比算法的迭代收敛曲线如图 2 所示。其中曲线纵轴为适应度值, 横轴为迭代次数, 可通过曲线的下降速率与最终收敛值, 直观对比不同算法的收敛特性与寻优性能。



**Figure 2.** Convergence curve  
**图 2.** 收敛曲线

从收敛曲线的变化趋势可以看出，EGCOA 在迭代初期就展现出显著快于其余 3 种对比算法的收敛速率，曲线下降幅度更大，说明精英反向学习机制生成的高质量初始种群，大幅提升了算法前期的全局勘探效率，可快速定位到优质解区域。在迭代中后期，EGCOA 仍能保持稳定的寻优能力，完成精细化的

局部深度开发。以 F3 测试函数的收敛过程为例, 算法的收敛速率随解的逼近有所放缓, 但仍能持续优化寻优结果, 不断向理论最优值逼近, 未出现早熟停滞的现象。综合数值统计结果与收敛特性分析可知, 本文提出的 EGCOA 具备更优质的初始解生成能力、更快的收敛速率与更高的寻优精度, 可有效规避早熟收敛问题、跳出局部最优解, 最终展现出更强的全局寻优能力与更优异的综合优化性能。

#### 4. 结论

本文针对原始小龙虾优化算法(COA)易早熟收敛、搜索能力协调不足等问题, 提出了一种基于精英引导自适应差分协同小龙虾优化算法(EGCOA)。该算法从种群初始化、个体更新和代际保留三个层面对 COA 进行了改进, 提升了种群多样性、全局搜索能力以及局部开发性能。实验结果表明, 所提 EGCOA 有效解决了原始算法易陷入局部最优的核心问题, 在收敛速度、寻优精度与运行鲁棒性上均有显著提升。同时, EGCOA 仍存在一定局限性, 例如多策略协同带来的计算开销增加、参数设置对性能的潜在影响, 以及在复杂约束、多目标和实际工程场景中的适用性仍有待进一步验证。

#### 基金项目

大学生创新创业训练计划资助项目(2025482, 2025496, 2025517)。

#### 参考文献

- [1] Yang, F., Wang, P., Zhang, Y., Zheng, L. and Lu, J. (2017) Survey of Swarm Intelligence Optimization Algorithms. 2017 *IEEE International Conference on Unmanned Systems (ICUS)*, Beijing, 27-29 October 2017, 544-549. <https://doi.org/10.1109/icus.2017.8278405>
- [2] Jia, H., Rao, H., Wen, C. and Mirjalili, S. (2023) Crayfish Optimization Algorithm. *Artificial Intelligence Review*, **56**, 1919-1979. <https://doi.org/10.1007/s10462-023-10567-4>
- [3] Heidari, A.A., Mirjalili, S., Faris, H., Aljarah, I., Mafarja, M. and Chen, H. (2019) Harris Hawks Optimization: Algorithm and Applications. *Future Generation Computer Systems*, **97**, 849-872. <https://doi.org/10.1016/j.future.2019.02.028>
- [4] Fu, X., Gou, Y. and Li, J. (2025) Broadband Impedance Matching Design Method for Dipole Acoustic Logging Transducer Based on Sparrow Search Algorithm. *Sensors and Actuators A: Physical*, **382**, Article 116143. <https://doi.org/10.1016/j.sna.2024.116143>
- [5] 易铎鑫, 张著洪. 改进型小龙虾优化算法设计与应用[J]. 集成电路应用, 2024, 41(11): 426-427.
- [6] 徐勇, 赵文贺. 基于多种策略改进的小龙虾优化算法[J]. 信息技术与信息化, 2025(10): 36-40.
- [7] Mahdavi, S., Rahnamayan, S. and Deb, K. (2018) Opposition Based Learning: A Literature Review. *Swarm and Evolutionary Computation*, **39**, 1-23. <https://doi.org/10.1016/j.swevo.2017.09.010>
- [8] Storn, R. and Price, K. (1997) Differential Evolution—A Simple and Efficient Heuristic for Global Optimization over Continuous Spaces. *Journal of Global Optimization*, **11**, 341-359. <https://doi.org/10.1023/a:1008202821328>