

DOI:10.20033/j.1003-7241.(2026)02-0017-04

## 多策略融合的改进天鹰优化器

李峰<sup>1</sup>, 张文伟<sup>1</sup>, 王翠林<sup>1</sup>, 邓文<sup>1</sup>, 樊小朝<sup>2</sup>

(1. 国网湖南省电力有限公司湘西供电分公司, 湖南吉首 416000; 2. 新疆工程学院 能源工程学院, 新疆乌鲁木齐 830023)

**摘要:** 针对智能优化算法存在全局勘探水平低、不易跳出局部最优等问题, 虽然天鹰优化器 (aquila optimizer, AO) 的提出, 使得此问题有所改善, 但仍无法应对未来愈发复杂的实际问题。为此, 针对天鹰优化器算法局部开发能力不足、全局寻优能力弱的问题, 提出了一种多策略融合的改进天鹰优化器 (improved Aquila optimizer with multi-strategy fusion, IAO-MSF)。首先, 基于反向学习策略和贪婪选择算法初始化种群, 提升当前种群接近全局最优的概率, 保证种群的多样性。然后, 利用自适应  $t$  分布变异策略具有较强的局部开发能力的优势, 替代原始天鹰优化器中的策略 3 和 4, 提高算法的局部开发能力, 并引入全局寻优能力较强的萤火虫算法, 对全种群进行萤火虫变异产生“新天鹰”个体, 进一步提升 IAO-MSF 的寻优性能。最后, 为验证本文所提 IAO-MSF 具有更强的寻优能力, 选择目前较为主流的 5 种智能优化算法进行对比, 在 1 个低维函数和 1 个高维函数以及 2 个复合基准函数上进行测试。结果表明, 相较于其余 5 种智能优化算法, 所提 IAO-MSF 具有更高的收敛精度、更快的收敛速度及较强的稳定性。

**关键词:** 天鹰优化器; 全局最优; 反向学习; 贪婪选择算法; 萤火虫算法; 自适应  $t$  分布变异; 新天鹰

**中图分类号:** TP391 **文献标志码:** A **文章编号:** 1003-7241(2026)02-0017-04

## Improved Aquila optimizer with multi-strategy fusion

LI Feng<sup>1</sup>, ZHANG Wenwei<sup>1</sup>, WANG Cuilin<sup>1</sup>, DENG Wen<sup>1</sup>, FAN Xiaochao<sup>2</sup>

(1. Engineering Research Center of Education Ministry for Renewable Energy Power Generation and Grid Connection, Jishou 416000, Hunan, China; 2. College of Energy Engineering, Xinjiang Engineering University, Urumqi 830023, Xinjiang, China)

**Abstract:** At present, the intelligent optimization algorithm has some problems, such as the low level of global exploration, and it is not easy to jump out of local optimization. Although the Aquila optimizer (AO) has improved this problem, it still cannot cope with the increasingly complex practical problems in the future. Therefore, in this paper, aiming at the problem that Aquila optimizer (AO) algorithm has insufficient local development ability and weak global optimization ability, an improved Aquila optimizer with multi-strategy fusion (IAO-MSF) is proposed. Firstly, the population is initialized based on reverse learning strategy and greedy selection algorithm, which improves the probability that the current population is close to the global optimum and ensures the diversity of the population. Then, the adaptive  $T$ -distribution mutation strategy has the advantage of strong local development ability, replacing strategies 3 and 4 in the original Aquila optimizer to improve the local development ability of the algorithm, and introducing the firefly algorithm with strong global optimization ability to mutate the whole population to produce "new Aquila" individuals for firefly mutation, further improving the optimization performance of IAO-MSF. Finally, in order to verify that the IAO-MSF proposed in this paper has stronger optimization ability, five mainstream intelligent optimization comparison algorithms are selected for comparison, and tests are carried out on 41 low-dimensional functions, 1 high-dimensional function and 2 composite benchmark functions. The results show that compared with the other five intelligent optimization algorithms, the IAO-MSF proposed in this paper has higher convergence accuracy, faster convergence speed and stronger stability.

**Keywords:** Aquila optimizer; global optimum; opposition-based learning; greedy selection algorithm; firefly algorithm; adaptive  $t$ -distribution mutation; new Aquila

随着社会的发展, 具有离散、无约束性质的优化问题愈发复杂多样, 传统智能优化算法已难以求解其最优解<sup>[1]</sup>。目前, 智能优化算法存在全局勘探水平低、不易跳出局部最优等问题。为此, 众多学者投身于新型智能优化算法及其改进研究中。

Abualigah 等<sup>[2]</sup>受到自然界天鹰捕猎的启发, 于 2021

年提出天鹰优化算法, 其为新型群体智能优化算法, 具有全局勘探水平高、收敛速度快、勘探开发效率高等优点, 但同时也存在难以跳出局部最优的缺点。针对此问题, 文献 [3] 提出一种改进的混合天鹰座优化器和哈里斯·霍克斯优化器 (harris hawks optimizer, HHO) 算法, 保留了 AO 的全局勘探能力与 HHO 的局部开采能力, 在利用阶段增

收稿日期: 2024-11-07; 录用日期: 2025-01-14

基金项目: 国家自然科学基金资助项目 (52266018); 新疆维吾尔自治区重大科技专项 (2022A01001-2)

作者简介: 李峰 (1974—), 男, 本科, 高级工程师, 研究方向: 电能计量管理、台区降损、采集运维管理等。

引用本文: 李峰, 张文伟, 王翠林, 等. 多策略融合的改进天鹰优化器 [J]. 自动化技术与应用, 2026, 45(2): 17-20. (LI Feng, ZHANG Wenwei, WANG Cuilin, et al. Improved Aquila optimizer with multi-strategy fusion [J]. Techniques of Automation and Applications, 2026, 45(2): 17-20.)

加反向学习策略,增强局部开采能力。最后,利用非线性逸出能量参数平衡组合算法的勘探和开发阶段,有效地增强了所提算法的探索和利用。文献[4]提出了一种融合算术优化算法与AO的混合算法,通过引入能量参数E平衡了混合算法群体中个体的勘探和开发过程,并引入分段线性映射降低了能量参数的随机性,实验结果表明该算法变得更优。文献[5]提出了一种改进的天鹰优化器(improved Aquila optimizer,IAO),该算法通过引入一个搜索控制因子,改进AO的狩猎策略,并整合反向学习<sup>[6]</sup>(opposition-based learning,OBL)与高斯突变策略<sup>[7]</sup>进一步提升AO的勘探和开发能力。因天鹰优化器提出时间较短,国外虽已有涉足,但国内对AO的研究鲜有涉及,且在解决实际问题时的性能仍有较大提升空间,故有必要进一步研究AO的改进,以便应对未来愈发复杂的实际问题。

为此,本文提出一种多策略融合的天鹰优化器,首先基于OBL策略与贪婪选择算法<sup>[8]</sup>(greedy algorithm,GA)进行初始化提高算法靠近全局最优解的概率。随后,当迭代次数小于 $2T/3$ 时采取AO策略1与2进行位置更新,当迭代次数大于 $2T/3$ 时采取自适应 $t$ 分布变异策略进行位置更新,提升算法局部开采能力。最后,引入萤火虫变异策略<sup>[9]</sup>,进一步提高算法的全局勘探与局部开采的能力。为验证所提IAO-MSF的有效性,选取4个含单模态、多模态、复合测试函数进行对比分析,结果表明,相较于AO,IAO-MSF在收敛精度、收敛速度、局部开采能力上均显著提升。

## 1 天鹰优化器的改进

为使AO具有更高的收敛精度、更快的收敛速度和更高的局部开采能力,在其基础上提出3个改进策略,具体如下。

### 1.1 种群初始化

鉴于OBL策略所产生的反向解群体比正向解群体在接近全局最优的几率上大约高出50%的优点,以及GA通过优化局部解得到局部最优解,进而得到近似的全局最优解的优点。本文基于OBL策略与GA进行种群初始化,使种群变得多样,降低算法陷入局部最优的概率。初始化过程如下。

- 1) 随机初始化种群生成初代种群 $X_{i,j}$ 。
- 2) 通过式(1)计算 $X_{i,j}$ 的反向解 $X_{i,j}^*$ 。

$$X_{i,j}^* = ub_{i,j} + lb_{i,j} - X_{i,j} \quad (1)$$

式中, $ub_{i,j}$ 和 $lb_{i,j}$ 分别为 $X_{i,j}$ 对应的第 $i$ 个个体当中第 $j$ 维的上限与下限。

3) 同时计算当前解与反向解的适应度值( $2N$ 个),将 $2N$ 个解进行排序得到最优的前 $N$ 个解,其后 $N$ 个解变成空解。然后,将得到的前 $N$ 个解作为初始种群中的个体。

### 1.2 自适应 $t$ 分布变异策略

$t$ 分布集合了柯西变异<sup>[10]</sup>与高斯变异的优点,既能在前期保持一个较高的全局搜索水平下,又能在后期有很强

的局部开采能力,故将造成原AO易陷入局部最优的 $X_3$ 、 $X_4$ 替换成自适应 $t$ 分布变异策略,当迭代次数 $t > (2T/3)$ 时采用自适应 $t$ 分布进行扰动。本文以最优解为导向对其进行自适应 $t$ 分布变异得到新解,并比较新、旧解,若新解更优则替换,反之则不,位置更新公式如下。

$$X_{i+1}^j = X_{best}^j + t(C\_Iter) \times X_{best}^j \quad (2)$$

式中, $X_{i+1}^j$ 为扰动后最优解在第 $j$ 维的位置; $t(C\_Iter)$ 是迭代次数Iter为 $t$ 分布的自由度参数的 $t$ 分布变异算子; $X_{best}^j$ 为扰动前最优解在第 $j$ 维的位置。

### 1.3 基于萤火虫算法的变异策略

为进一步提升AO的寻优能力,本文将具有参数少、易实现、全局寻优能力强等特点的萤火虫算法(firefly algorithm,FA)与AO相结合。在上述改进策略下对全种群进行萤火虫变异产生新个体(本文将带有萤火虫特性的天鹰称为新天鹰),然后计算其适应度,并比较新旧适应度,若新个体更优则替换,反之则不替换。

若 $X_i = (x_{1i}, x_{2i}, \dots, x_{di}, i = 1, 2, \dots, N)$ 是群体中的第 $i$ 只新天鹰, $N$ 与 $d$ 分别为种群中新天鹰的个数与修正参数的维度,则种群中任意两只新天鹰 $X_i$ 和 $X_j(i \neq j)$ 之间的欧氏距离 $r_{ij}$ 为

$$r_{ij} = \|X_i - X_j\| = \sqrt{\sum_{k=1}^d (x_{ik} - x_{jk})^2} \quad (3)$$

同时,两只新天鹰之间的吸引力因子为

$$\beta_{ij} = \beta_0 \cdot e^{-\gamma \cdot r_{ij}^2} \quad (4)$$

式中, $\beta_0$ 为两只新天鹰的欧氏距离为0时的吸引力,值一般取1; $\gamma$ 为光在空气中的衰减系数,值一般为0.01~100。

若新个体的适应度比原个体适应度更优,则新天鹰的位置进行更新,其公式为

$$X_i^{t+1} = X_i^t + \beta_{ij}^t (X_j^t - X_i^t) + \alpha_2 \cdot e \quad (5)$$

式中, $j = 1, 2, \dots, i-1, \dots, N$ ,上标 $t$ 为当前迭代步数; $\alpha_2$ 为步长因子,取值0~1; $e$ 为 $d$ 维随机向量,服从正态分布 $N(0,1)$ 。

IAO-MSF实现流程如下:

**步骤1** 假设初始化种群的数量为 $N$ ,维数为Dim,迭代次数最大值为 $T$ 。

**步骤2** 结合OBL策略和GA对种群( $X$ )进行初始化,计算适应度值,记录最优个体。

**步骤3** 当 $t \leq (2/3)T$ 时,个体随机选择或开始探索行为。

**步骤4** 当 $t > (2/3)T$ 时,对当前全局最优解进行自适应 $t$ 分布变异,根据式(2)更新最优解。

**步骤5** 进行萤火虫扰动,形成新一代具有萤火虫特性的天鹰,然后根据式(5)更新位置。

**步骤6** 判断是否达到最大迭代次数。若是,则终止循环并输出最优值 $f_{min}$ 和最优解 $X_{best}$ ,否则,回到步骤3。

## 2 仿真实验与结果分析

### 2.1 测试函数

为验证本文所提IAO-MSF有更好的寻优性能,本文

选取文献[11]中的4个基准函数对6种算法寻优能力进行对比实验,其中 $f_1$ 为单模态的基准测试函数,此类函数只有一个最小值,因此可用于测试算法的收敛速度; $f_2$ 为多模态的基准测试函数,此类函数存在多个极小值,可用于测试算法全局寻优与跳出局部最优的能力。 $f_3-f_4$ 为复合基准测试函数。

2.2 比较对象及参数设置

为验证IAO-MSF中改进策略的有效性,本文选取AO、FA、金豺优化算法<sup>[12]</sup>(golden jackal optimization, GJO)、鲸鱼

优化算法<sup>[13]</sup>(whale optimization algorithm, WOA)及灰狼优化算法<sup>[14-15]</sup>(grey wolf optimizer, GWO)与IAO-MSF进行对比。为使本次对比实验公平有效,设 $N=30, T=500$ ,其余参数设置同文献[16]。

2.3 算法性能对比分析

将上述6种算法分别在Dim为50/500/1000的基准函数条件下独立运行30次后进行对比。在算法性能优劣的评定中,将最优值、平均值与标准差作为其指标,各算法迭代寻优结果如表1和表2所示。

表1 低维、高维基准函数下的算法性能对比

Tab.1 Comparison of algorithm performance under low-dimensional and high-dimensional benchmark functions

函数	算法	Dim=50			Dim=500			Dim=1000		
		最优值	平均值	标准差	最优值	平均值	标准差	最优值	平均值	标准差
$f_1$	IAO-MSF	0.00e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00
	AO	1.46e-160	5.79e-100	3.16e-99	1.31e-160	4.76e-100	2.60e-99	2.06e-158	2.68e-100	1.46e-99
	GJO	2.39e-57	3.41e-54	1.55e-53	3.60e-57	3.25e-54	1.23e-53	8.12e-59	1.36e-54	2.18e-54
	WOA	5.56e-86	6.08e-73	3.27e-72	9.35e-85	2.42e-74	9.11e-74	7.57e-88	1.03e-72	5.65e-72
	GWO	1.39e-29	1.34e-27	1.74e-27	1.87e-29	1.05e-27	1.15e-27	6.86e-29	2.16e-27	3.02e-27
	FA	6.85e-08	1.06e-07	1.57e-08	6.91e-08	1.07e-07	1.68e-08	6.94e-08	1.11e-07	1.75e-08
$f_2$	IAO-MSF	8.88e-16	8.88e-16	0.00e+00	8.88e-16	8.88e-16	0.00e+00	8.88e-16	8.88e-16	0.00e+00
	AO	8.88e-16	8.88e-16	0.00e+00	8.88e-16	8.88e-16	0.00e+00	8.88e-16	8.88e-16	0.00e+00
	GJO	4.44e-15	6.80e-15	1.70e-15	4.44e-15	7.16e-15	1.52e-15	4.44e-15	7.16e-15	1.52e-15
	WOA	8.88e-16	4.20e-15	2.27e-15	8.88e-16	3.37e-15	2.66e-15	8.88e-16	4.08e-15	2.52e-15
	GWO	7.54e-14	1.08e-13	1.63e-14	7.54e-14	1.02e-13	1.73e-14	7.90e-14	1.02e-13	1.39e-14
	FA	6.55e-05	7.73e-05	6.67e-06	6.99e-05	7.83e-05	3.89e-06	6.47e-05	7.56e-05	4.63e-06

表2 复合基准测试函数下的算法性能对比

Tab.2 Comparison of algorithm performance under composite benchmark functions

函数	$f_3$						$f_4$					
	IAO-MSF	AO	GJO	WOA	GWO	FA	IAO-MSF	AO	GJO	WOA	GWO	FA
最优值	9.98e-01	9.98e-01	9.98e-01	9.98e-01	9.98e-01	9.98e-01	3.00e+00	3.00e+00	3.00e+00	3.00e+00	3.00e+00	3.00e+00
平均值	1.94e+00	3.37e+00	7.37e+00	3.51e+00	4.36e+00	1.03e+00	3.00e+00	3.03e+00	5.70e+00	3.00e+00	3.00e+00	3.00e+00
标准差	2.17e+00	4.29e+00	4.68e+00	3.42e+00	3.83e+00	1.81e-01	1.79e-04	3.52e-02	1.47e+01	4.80e-05	2.79e-05	8.99e-14

2.3.1 低维测试函数下的算法对比

由表1可知,当维度为50时IAO-MSF的求解性能优于GJO、WOA、GWO、FA,其中IAO-MSF的最优值、平均值和标准差均更优,IAO-MSF在函数 $f_1$ 上的寻优效果也达到100%,可直接找到理论最优值。对于 $f_2$ ,IAO-MSF的寻优效果虽优于其余算法,但6种算法对此函数的寻优结果均不理想。相较其余5种算法,IAO-MSF在函数 $f_1-f_2$ 上的标准差为0,表明改进算法稳定性较强,OBL策略与GA的结合保证了算法种群的多样性,亦说明自适应t分布及萤火虫变异策略在一定程度上提高了算法的寻优精度。在复合基准测试函数下IAO-MSF仍可直接搜寻到最优解,其标准差也优于AO,鲁棒性较好。综上所述,IAO-MSF的整体寻优性能优于其余5种算法。

2.3.2 高维测试函数下的算法对比

由上述函数在Dim=50下的寻优结果可知,在低维测试函数上,IAO-MSF拥有较好的寻优效果。但在现实工程应用中,高维复杂优化问题的占比更大,而群体智能算法在处理较为复杂的高维问题时,其求解效果易大打折扣,故为证明本文所提IAO-MSF在求解高维函数时的优越性,进行测试函数在500和1000维度下的测试。

为更加直观地对比不同算法的收敛效果,本文将展示单模态与多模态2个基准测试函数的收敛曲线图,如图1所示。

由表1和表2可知,当IAO-MSF求解高维测试函数时,其求解精度及鲁棒性相较于低维测试函数差异较小,寻优效果均较为理想。其中 $f_1$ 与 $f_3-f_4$ 可直接达到最优值,未出现“维数灾难”的问题,表明IAO-MSF的稳定性较好。

由图1可知,IAO-MSF的收敛速度和精度均高于AO、

GJO与FA。 $f_1$ 为单模态函数,主要用于测试算法的全局勘探水平及收敛快慢,由图1(a)可知,萤火虫变异策略的引入使算法的全局勘探水平进一步提升,即IAO-MSF具有比AO更快的收敛速度与更高的收敛精度。 $f_2$ 为多模态函

数,主要用于测试算法的局部开发能力,由图1(b)可知,当迭代次数大于 $2T/3$ 时收敛曲线直线逼近最优值,原因在于自适应 $t$ 分布变异策略替代AO的策略3和4后,提高了AO的局部开发能力,使其寻优性能大幅度提升。




图1 单模态和多模态基准函数下的收敛曲线对比图

Fig. 1 Comparison of convergence curves under single-mode and multi-mode reference functions

综上所述,IAO-MSF对4个基准测试函数的求解效果均有显著提升,具有较强的鲁棒性,IAO-MSF的收敛速度及精度均得到断崖式提升,且在求解高维多模态函数时,在保持全局勘探高水准的同时,其局部开发能力也较强。至此,IAO-MSF的有效性和优越性得以证明。

### 3 结论

本文提出一种多策略融合的天鹰优化器,通过结合OBL策略与GA,使种群变得更加多样,并提升接近最优解的概率,然后将自适应 $t$ 分布变异策略替代原AO的策略3和4,改善了算法易陷入局部最优的不足,在此基础上进一步实施萤火虫变异再一次提升了整个算法的全局搜索能力及局部寻优能力。通过1个低维函数、1个高维函数和2个复合基准函数的测试结果表明,IAO-MSF具有较强的跳脱局部最优的能力、更高的收敛速度及精度。在下一步研究中将进一步考虑将IAO-MSF应用至风电、光伏功率预测,短期电负荷预测,求解综合能源系统容量配置与优化调度等实际问题中。

### 参考文献

[1]徐亦凤,刘升,刘宇崧,等.融合差分变异和切线飞行的天鹰优化器[J].计算机应用研究,2022,39(10):2996-3002.  
[2]ABUALIGAH L, YOUSRI D, ABD ELAZIZ M, et al. Aquila optimizer: a novel meta-heuristic optimization algorithm[J]. Computers & Industrial Engineering, 2021(157):107250.

[3]WANG S, JIA H, ABUALIGAH L, et al. An improved hybrid aquila optimizer and harris hawks algorithm for solving industrial engineering optimization problems[J]. Processes, 2021, 9(9):1551.  
[4]MAHAJAN S, ABUALIGAH L, PANDIT A K, et al. Hybrid Aquila optimizer with arithmetic optimization algorithm for global optimization tasks[J]. Soft Computing, 2022, 26(10):4863-4881.  
[5]GAO B, SHI Y, XU F, et al. An improved aquila optimizer based on search control factor and mutations[J]. Processes, 2022, 10(8):1451.  
[6]李智杰,赵铁柱,李昌华,等.融合多策略的改进鸢鹫优化算法[J].控制工程,2025,32(7):1184-1197,1206.  
[7]杨志龙,邹德旋,李灿,等.融入限制反向学习与柯西-高斯变异的蜣螂优化算法[J].计算机应用,2025,45(7):2304-2316.  
[8]刘晓斌,沙宗尧.基于IACO改进Logistic混沌序列的WSN布局优化[J].自动化技术与应用,2024,43(10):131-133.  
[9]赵嘉,胡秋敏,肖人彬,等.求解大规模稀疏优化问题的高维多目标萤火虫算法[J].控制与决策,2024,39(12):3989-3996.  
[10]宋江涛,崔双喜,樊小朝,等.基于SGMD-SE与优化TCN-BiLSTM/BiGRU的超短期风功率预测[J].太阳能学报,2024,45(10):588-596.  
[11]申元霞,张学锋,方馨,等.多尺度正余弦优化算法[J].控制与决策,2022,37(11):2860-2868.  
[12]林雨珊,刘升.多策略强化的金豺优化算法[J].计算机应用研究,2024,41(12):3679-3688.  
[13]贾俊,袁栋,戴永东,等.基于深度学习算法的配网设备状态智能巡检方法[J].自动化技术与应用,2024,43(12):80-83,158.  
[14]刘晖,朱德康,许凌杰,等.基于改进灰狼算法优化支持向量机的边坡位移预测[J].自动化技术与应用,2024,43(9):30-33,171.  
[15]周宣.融合GWO算法与BP神经网络的小电流接地选线装置研究[J].自动化技术与应用,2025,44(5):155-159.  
[16]郑婷婷,刘升,叶旭.自适应 $t$ 分布与动态边界策略改进的算术优化算法[J].计算机应用研究,2022,39(5):1410-1414.