

吴昌寅, 张军. 混合策略改进的北方苍鹰优化算法及其应用[J]. 智能计算机与应用, 2025, 15(7): 1-10. DOI: 10.20169/j.issn.2095-2163.24101005

混合策略改进的北方苍鹰优化算法及其应用

吴昌寅, 张 军

(上海电力大学 自动化工程学院, 上海 200090)

摘 要: 针对传统北方苍鹰优化算法(NGO)存在收敛速度慢、收敛精度低和易达到局部最优等问题,提出了混合策略改进的北方苍鹰优化算法(INGO)。INGO算法采用最优个体引领策略,提高算法的收敛速率与精度;融合减法平均优化器(SABO)进行位置更新,有效增强算法跳出局部最优的能力,从而加速全局收敛进程;通过添加概率因子引入柯西变异策略,增加种群多样性,强化算法的全局搜索能力,更好地达到全局最优;基于上下限值进行位置动态更新,优化搜索效率并增强算法鲁棒性。通过14个基准测试函数对INGO算法进行寻优测试,并与其他优化算法对比,结合Wilcoxon秩和检验分析,实验结果表明,INGO算法具有更快的收敛速度和更高的收敛精度。将INGO算法用于静压推力轴承设计优化问题,进一步证明了改进北方苍鹰优化算法在解决实际工程问题时的可行性和优越性。

关键词: 北方苍鹰优化算法; 最优个体引领; 减法平均优化器算法; 柯西变异; 工程应用

中图分类号: TP182

文献标志码: A

文章编号: 2095-2163(2025)07-0001-10

Improved Northern Goshawk Optimization Algorithm with hybrid strategy and its applications

WU Changyin, ZHANG Jun

(School of Automation Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: Addressing the issues of slow convergence speed, low convergence accuracy, and susceptibility to local optima in the traditional Northern Goshawk Optimization (NGO) algorithm, an Improved Northern Goshawk Optimization (INGO) algorithm with hybrid strategies is proposed. The INGO algorithm adopts an optimal individual-led strategy to enhance the convergence rate and accuracy of the algorithm. It integrates the Subtraction Average Optimizer (SABO) for position updating, effectively bolstering the algorithm's ability to escape local optima and thus accelerating the global convergence process. By incorporating a Cauchy mutation strategy through the addition of a probability factor, population diversity is increased, reinforcing the algorithm's global search capabilities and facilitating better attainment of the global optimum. Based on upper and lower limit values, dynamic position updating is implemented to optimize search efficiency and enhance the algorithm's robustness. The INGO algorithm is tested for optimization using 14 benchmark functions and compared with other optimization algorithms. Coupled with Wilcoxon rank-sum test analysis, the experimental results demonstrate that the INGO algorithm exhibits faster convergence speed and higher convergence accuracy. The application of the INGO algorithm to the design optimization problem of hydrostatic thrust bearings further proves the feasibility and superiority of the improved Northern Goshawk Optimization algorithm in solving practical engineering problems.

Key words: Northern Goshawk Optimization Algorithm; best individual leading; Subtraction-based Average Optimizer Algorithm; Cauchy mutation; engineering application

0 引言

随着信息技术的日新月异,工程问题的复杂程度与日俱增。因此,寻求高效实用的优化方法变得至关重要。群智能优化算法是一类深受自然界群体行为

启发的智能计算方法,巧妙地模拟了昆虫觅食、兽群迁徙、鸟群飞行和鱼群游动等自然现象中的协作与决策过程。通过抽象和模拟这些群体在复杂环境中展现出的高效协同机制,为解决各类复杂的优化问题提供了新颖而有效的途径。因此,群智能优化算法已成

基金项目: 国家自然科学基金(61273190)。

作者简介: 吴昌寅(1998—),男,硕士研究生,主要研究方向:智能控制与优化算法。

通信作者: 张 军(1966—),男,博士,副教授,硕士生导师,主要研究方向:新能源设备开发与智能制造。Email: 86610598@qq.com。

收稿日期: 2024-10-10

哈尔滨工业大学主办 ◆ 学术研究与应用

为工程优化^[1]、数据挖掘^[2]、智能控制^[3]等多个领域不可或缺的工具,极大地推动这些领域的进步与发展。在群智能算法的探索中,该领域已经见证多种高效算法的创新与涌现,其中包括减法平均优化器算法(SABO)^[4]、金豺优化算法(GJO)^[5]、麻雀优化算法(SSA)^[6]以及蜣螂优化算法(DBO)^[7]等等。

北方苍鹰优化(Northern Goshawk Optimization, NGO)^[8]算法是由 Dehghani 等通过模拟北方苍鹰狩猎行为,于 2021 年提出的一种新元启发式优化算法。该算法能够在勘探和开发阶段之间保持平衡,相比于其他同类算法具有更强的优化性能,众多学者纷纷尝试将这一算法应用于各类工程项目中,并且取得了显著成效。倪金等^[9]采用 NGO 算法对核极限学习机(KELM)模型的参数进行优化,使其在玉米品种分类上显著提升了分类的准确率。Chang 等^[10]运用 NGO 算法解决风能-太阳能互补发电系统的混合储能容量优化配置问题,不仅降低系统成本,而且提高收敛速度,还减小了优化波动范围,提高整体的优化稳定性。Zhong 等^[11]将 NGO 算法应用于优化双向长短期记忆网络(BiLSTM)的超参数优化中,有效地改善面部表情识别的性能,显著提升识别的准确率和效率。上述文献详细地展示了北方苍鹰优化算法在解决一系列工程问题的实际应用价值,但与其他元启发式算法一样,在迭代后期也不可避免地面临着收敛速度减缓和陷入局部最优的困境。众多学者针对该问题进行深入地改进研究,努力增强算法的性能。仝柯等^[12]提出一种多策略融合改进的北方苍鹰优化算法,通过引入随机反向学习策略增强种群多样性,结合自适应权重因子与非线性收敛因子优化搜索过程,提高算法的全局探索与局部开发能力。张轲钦等^[13]通过拉丁超立方抽样初始化种群以增强样本分布的均匀性,引入正态云模型以增加种群多样性,并结合动态位置自适应调整和柯西变异策略来改进北方苍鹰优化算法,提升算法的全局搜索能力,有效避免局部最优。

总而言之,尽管这些改进策略在一定程度上提升了北方苍鹰优化算法的性能,但仍存在一些局限性。本文创新性地提出混合策略改进的北方苍鹰优化算法(INGO)。

1 北方苍鹰优化算法

在捕猎的第一阶段,即猎物识别的勘探阶段,北方苍鹰会随机锁定一个潜在的猎物,随后迅速发动攻击。北方苍鹰行为的数学表达式如下:

$$P_i = X_k, (i = 1, 2, \dots, N; k = 1, 2, \dots, i - 1, \dots, N) \quad (1)$$

$$X_{i,j}^{new,p1} = \begin{cases} X_{i,j} + r(P_{i,j} - IX_{i,j}), & F_{P_i} < F_i \\ X_{i,j} + r(X_{i,j} - P_{i,j}), & F_{P_i} \geq F_i \end{cases} \quad (2)$$

$$X_i = \begin{cases} X_i^{new,p1}, & F_i^{new,p1} < F_i \\ X_i, & F_i^{new,p1} \geq F_i \end{cases} \quad (3)$$

式中: P_i 为第 i 只苍鹰猎物的位置, F_{P_i} 为其目标函数值, k 为 $[1, N]$ 内随机的整数, $X_{i,j}$ 为第 i 只苍鹰的第 j 维位置, $P_{i,j}$ 为第 i 只苍鹰的第 j 维猎物的位置, $X_i^{new,p1}$ 为第 i 只苍鹰的新位置, $X_{i,j}^{new,p1}$ 为第 i 只苍鹰的第 j 维的新位置, $F_i^{new,p1}$ 为第 1 阶段更新后其对应的目标函数值, r 为 $[0, 1]$ 范围内的随机数, I 为 $\{1, 2\}$ 之间的随机数。

在第二步的追逐与逃生开发阶段,当北方苍鹰成功锁定并攻击猎物,猎物会本能地试图逃跑。然而,苍鹰以其惊人的速度和敏捷性,在追逐过程中展现出无与伦比的捕捉能力。无论猎物如何挣扎和逃生,苍鹰都能迅速调整自身,保持追踪,并在关键时刻准确发动致命攻击,确保捕获猎物。此阶段数学表达式如下:

$$X_{i,j}^{new,p2} = X_{i,j} + R(2r - 1)X_{i,j} \quad (4)$$

$$R = 0.02 \times \left(1 - \frac{t}{T}\right) \quad (5)$$

$$X_i = \begin{cases} X_i^{new,p2}, & F_i^{new,p2} < F_i \\ X_i, & F_i^{new,p2} \geq F_i \end{cases} \quad (6)$$

式中: R 为狩猎半径, t 为当前运行次数, T 为最大运行次数, $X_i^{new,p2}$ 为第 2 阶段更新的新位置, $X_{i,j}^{new,p2}$ 为第 2 阶段第 i 只苍鹰的第 j 维的位置, $F_i^{new,p2}$ 为其目标函数值。

2 改进的北方苍鹰优化算法

2.1 最优个体引领策略

在 NGO 的第一阶段,当 $F_{P_i} < F_i$ 时,是在特定条件下随机选择一只苍鹰来引导整个种群进行位置更新。这种方法虽然有助于算法的快速收敛,但也带来了盲目性,因为没有基于任何明确的优化策略来选择引导者。为此,本文采用最优个体引领策略^[14]进行位置更新,算法不再随机选择引导者,而是始终选择当前种群中最优苍鹰作为引导,从而提高算法的搜索效率和优化效果。改进公式如下:

$$X_{i,j}^{new,p1} = X_{i,j} + r(x_{best} - IX_{i,j}) \quad (7)$$

式中 x_{best} 为每一代的最优苍鹰。

2.2 减法平均优化器算法

在第一阶段中,当 $F_{p_i} \geq F_i$ 时,算法可能存在随机性和陷入局部最优的风险。受减法平均优化器 (SABO) 的启发,本文融合 SABO 进行位置更新,可以有效地引导整个种群的搜索方向。这种更新方法不仅利用 SABO 在全局粒子更新上的能力,还确保种群能够更高效地探索搜索空间,从而降低陷入局部最优的可能性。改进后的北方苍鹰算法位置更新公式如下:

$$X_{i,j}^{new,p1} = X_{i,j} + \vec{r} \times \frac{1}{N} \sum_{k=1}^N (X_i - {}_v X_k) \quad (8)$$

$$X_i - {}_v X_k = \text{Sign}(F_{X_i} - F_{X_k}) (X_i - \vec{v} \times X_k) \quad (9)$$

式中: $\vec{r}$ 为服从正态分布的随机值, ${}_v$ 为搜索代理 X_k 与搜索代理 X_i 的 v -减法,定义如式(9), $\vec{v}$ 为 $[1,2]$ 内随机生成的维度向量, F_{X_i} 、 F_{X_k} 分别为 X_i 、 X_k 的目标函数值。

由式(8)可知,通过融合 SABO,INGO 能够综合考虑全局的位置信息,来不断更新种群中苍鹰的位置。这种全局性的更新策略,显著增强算法在搜索过程中跳出局部最优的能力,从而加速全局的收敛速度。

2.3 柯西变异策略

在 NGO 的第二阶段,为了扩大种群的多样性并提升算法的全局探索能力,添加一定概率因子的柯西变异^[15]策略,有助于算法更有效地跳出局部最优,向全局最优逼近。通过引入这种变异策略,INGO 在求解优化问题时能够展现出更强的适应性和探索能力。添加概率因子的柯西变异公式如下:

$$X_{best}^{new} = X_{best} + X_{best} \times \text{Cauchy}(0,1), \text{rand} < \sigma \quad (10)$$

式中:当 $\text{rand} < \sigma$ 时,采用概率因子的柯西变异策略, σ 为变异因子,设置为 0.2; $\text{Cauchy}(0,1)$ 为标准的柯西变异函数; X_{best} 为当前全局最优解; X_{best}^{new} 为柯西变异后的全局最优解。

2.4 上下限值策略

在第二阶段中,为了优化搜索策略和加速算法的收敛能力,当 $\text{rand} > \sigma$ 时,引进上下限值来进行动态更新,逐步缩减搜索范围,便于有效地定位目标位置。随着迭代过程的不断推进,算法对目标搜索范围将呈现出一个动态缩小的趋势,从而更加精确地定位最优解的位置。这种方式不仅提高算法的搜索效率,还有助于 INGO 更快地收敛到全局最优。改进后的计算公式如下:

$$X_{i,j}^{new,p2} = X_{i,j} + \frac{R(2r-1)(ub-lb)}{t} \quad (11)$$

式中: t 为迭代次数, ub 为上限值, lb 为下限值。

2.5 INGO 算法流程

INGO 算法的具体实现步骤如下:

步骤 1 初始参数设定,包括确立种群大小、设定最大迭代次数、界定搜索空间的上下限、以及明确维度特性等;

步骤 2 随机生成苍鹰种群,并根据其代表的解计算对应的适应度值;

步骤 3 选择当前苍鹰种群中最优个体作为引导,由式(7)更新苍鹰的位置;

步骤 4 由式(8)更新苍鹰的位置;

步骤 5 若 $\text{rand} < 0.2$,则使用柯西变异,由式(10)更新苍鹰位置;否则,由式(11)更新苍鹰位置;

步骤 6 更新全局最优值;

步骤 7 检查是否满足迭代终止条件,若满足,则输出全局优化值,否则转至步骤 3 以进行下一轮的迭代搜索。

INGO 算法流程如图 1 所示:




图 1 INGO 算法流程图

Fig. 1 Flowchart of the INGO algorithm

3 实验结果与分析

3.1 实验环境

本文所有实验测试均在计算机配置为 CPU Intel Core i5-8300H, 内存 8 GB, 64 位 Windows 10 操作系统中运行。程序代码使用 Matlab 2023b 实

现,保证了实验结果的准确性和合理性。

3.2 INGO 算法精度测试

为了验证所提 INGO 算法的有效性和优越性,选择常用的 14 个基准测试函数^[16]进行实验,其数学表达式见表 1。其中, $F_1 \sim F_6$ 为单峰函数,仅具有一个全局最优解,没有局部最优解; $F_7 \sim F_{10}$ 为多峰

函数,存在多个局部最优解,其中一个或多个是全局最优解; $F_{11} \sim F_{14}$ 为固定维度多峰函数,不仅具有多个局部最优解,且其维度是固定的。通过实验测试,可以全面评估 INGO 算法在求解精度、收敛速度、全局搜索能力和局部开发能力等方面的性能表现。

表 1 基准测试函数

Table 1 Benchmark test functions

函数名称	测试函数	范围	维度	最优值
Sphere	$F_1(x) = \sum_{i=1}^n x_i^2$	$[-100,100]$	30	0
Schwefel 2. 22	$F_2(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	$[-10,10]$	30	0
Schwefel 1. 2	$F_3(x) = \sum_{i=1}^n (\sum_{j=1}^i x_j)^2$	$[-100,100]$	30	0
Schwefel 2. 21	$F_4(x) = \max x_i \{ x_i , 1 \leq i \leq n \}$	$[-100,100]$	30	0
Rosenbrock	$F_5(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	$[-30,30]$	30	0
Quartic	$F_6(x) = \sum_{i=1}^n ix_i^4 + \text{random}[0,1)$	$[-1.28,1.28]$	30	0
Schwefel 2. 26	$F_7(x) = \sum_{i=1}^n -x_i \sin(\sqrt{ x_i })$	$[-500,500]$	30	-12 569.500 0
Ackley	$F_8(x) = -20\exp(-0.2\sqrt{\frac{1}{n}\sum_{i=1}^n x_i^2}) - \exp(\frac{1}{n}\sum_{i=1}^n \cos(2\pi x_i)) + 20 + e$ $F_9(x) = \frac{\pi}{n}\{10\sin(\pi y_1) + \sum_{i=1}^{n-1} (y_i - 1)^2[1 + 10\sin^2(\pi y_i + 1)] + (y_n + 1)^2\} + \sum_{i=1}^n u(x_i,10,100,4)$ $y_i = 1 + \frac{x_i + 1}{4},$	$[-32,32]$	30	0
Penalized 1	$u(x_i,a,k,m) = \begin{cases} k(x_i - a)^m, & x_i > a \\ 0, & -a < x_i < a \\ k(-x_i - a)^m, & x_i < -a \end{cases}$	$[-50,50]$	30	0
Penalized 2	$F_{10}(x) = 0.1 \left\{ \frac{\sin^2(3\pi x_1) + \sum_{i=1}^n (x_i - 1)}{1 + \sin^2(3\pi x_i + 1) + (x_n - 1)^2[1 + \sin^2(2\pi x_n)]} \right\} + \sum_{i=1}^n u(x_i,5,100,4)$	$[-50,50]$	30	0
Shekell	$F_{11}(x) = (\frac{1}{500} + \sum_{j=1}^{25} \frac{1}{j + \sum_{i=1}^2 (x_i - a_{ij})^6})^{-1}$	$[-65,65]$	2	1
Kowalik	$F_{12}(x) = \sum_{i=1}^{11} [a_i - \frac{x_1(b_i^2 + b_1x_2)}{b_i^2 + b_1x_3 + x_4}]^2$	$[-5,5]$	4	0.000 3
Branin	$F_{13}(x) = (x_2 - \frac{5.1}{4\pi^2}x_1^2 + \frac{5}{\pi}x_1 - 6)^2 + 10(1 - \frac{1}{8\pi})\cos x_1 + 10$	$[-5,5]$	2	0.398 0
Shekel 3	$F_{14}(x) = -\sum_{i=1}^{10} [(X - a_i)(X - a_i)^T + c_i]^{-1}$	$[0,10]$	4	-10

3.3 INGO 算法与各算法的寻优对比

为了全面验证 INGO 的性能,选择经典及近期提出的优化算法作为对比,其中包括麻雀优化算法(SSA)、蜣螂优化算法(DBO)、减法平均优化器算法(SABO)、金豺优化算法(GJO)以及传统北方苍鹰优化算法(NGO)等等。实验中保证对比实验的公正

性,采用标准化设置,即种群数量为 50,最大迭代次数为 500,每种算法均被独立地重复执行 30 次。对比算法的其他参数与文献[17-23]中保持一致,最后通过最优值(Best)、平均值(Mean)以及标准差(Std)来验证 INGO 的优越性,对比结果见表 2 和表 3。

表 2 6 种算法寻优结果对比 (30 维)

Table 2 Comparison of optimization results of 6 algorithms (30-dimensional)

函数	统计值	INGO	NGO	SABO	DBO	SSA	GJO
F_1	Best	0	5.33e-206	0	0	0	1.15e-229
	Mean	0	5.58e-201	0	9.02e-236	3.17e-103	4.09e-221
	Std	0	0	0	0	1.74e-102	0
F_2	Best	0	8.79e-106	5.92e-223	2.58e-160	4.04e-94	5.04e-125
	Mean	0	3.71e-103	2.19e-219	7.62e-118	2.74e-54	2.83e-121
	Std	0	7.98e-103	0	4.17e-117	1.05e-53	7.77e-121
F_3	Best	0	1.05e-98	5.54e-225	4.89e-276	3.35e-231	3.68e-132
	Mean	0	9.43e-92	5.75e-183	3.48e-176	1.96e-69	2.33e-114
	Std	0	4.58e-91	0	0	1.06e-68	1.24e-113
F_4	Best	0	1.25e-91	1.48e-173	1.92e-162	1.34e-155	1.44e-87
	Mean	0	4.50e-90	4.75e-170	3.35e-112	3.80e-38	2.64e-81
	Std	0	5.84e-90	0	1.71e-111	2.08e-37	9.36e-81
F_5	Best	0	0.05	5.99	0.22	1.34e-13	6.13
	Mean	0	0.24	7.19	3.98	9.54e-07	6.89
	Std	0	0.19	0.60	0.81	2.79e-06	0.76
F_6	Best	1.59e-06	5.51e-05	1.92e-06	4.60e-05	3.87e-05	5.05e-06
	Mean	2.33e-05	0.000 2	4.11e-05	0.000 6	0.000 3	8.79e-05
	Std	2.43e-05	9.09e-05	3.52e-05	0.000 4	0.000 2	9.65e-05
F_7	Best	-3 109.80	-3 854.25	-2 191.26	-4 189.73	-3 854.25	-3 321.01
	Mean	-2 957.24	-3 436.46	-1 810.75	-3 500.90	-3 217.45	-2 382.87
	Std	110.93	212.66	170.59	435.82	281.40	405.60
F_8	Best	4.44e-16	3.99e-15	3.99e-15	4.44e-16	4.44e-16	4.44e-16
	Mean	4.44e-16	3.99e-15	3.99e-15	5.63e-16	4.44e-16	3.76e-15
	Std	0	0	0	6.49e-16	0	9.01e-16
F_9	Best	4.71e-32	9.41e-32	0.000 4	4.83e-32	4.71e-32	3.59e-06
	Mean	4.71e-32	7.91e-27	0.04	3.47e-22	4.79e-32	0.03
	Std	1.67e-47	2.87e-26	0.07	1.99e-21	1.16e-33	0.02
F_{10}	Best	1.35e-32	7.84e-29	0.004	3.32e-32	1.35e-32	7.36e-06
	Mean	1.35e-32	0.002	0.17	0.03	1.53e-32	0.14
	Std	5.57e-48	0.004	0.19	0.04	3.59e-33	0.09
F_{11}	Best	0.99	0.99	0.99	0.99	0.99	0.99
	Mean	0.99	0.99	3.19	1.72	6.12	5.43
	Std	9.55e-10	0	2.11	1.85	5.72	4.49
F_{12}	Best	0.000 3	0.000 3	0.000 3	0.000 3	0.000 3	0.000 3
	Mean	0.001	0.000 3	0.001	0.000 8	0.000 3	0.001
	Std	0.004	3.89e-06	0.002	0.000 3	7.04e-05	0.004
F_{13}	Best	0.397 9	0.397 9	0.40	0.39	0.39	0.39
	Mean	0.397 9	0.397 9	0.47	0.39	0.39	0.40
	Std	4.68e-06	0	0.15	0	0	0.001
F_{14}	Best	-10.53	-10.54	-7.97	-10.54	-10.54	-10.53
	Mean	-7.79	-10.54	-4.74	-7.79	-9.82	-9.45
	Std	2.71	3.28e-06	0.93	3.06	1.87	2.19

表 2、表 3 分别给出在低维和高维搜索空间下, 6 种算法在 14 个测试函数中的最优值、平均值和标准差寻优对比结果。其中, $F_1 \sim F_{10}$ 分别设置为 30 维和 100 维, $F_{11} \sim F_{14}$ 为固定维数。由表中的数据可知, 从整体性能上来看 INGO 在寻优上位居榜首。

在单峰函数 $F_1 \sim F_5$ 中, INGO 都达到理论最优值, 且 SABO 在 F_1 上也达到理论最优, 虽然其他算法未达到理论上的最优解, 但也展现出极高的收敛精度。在 F_6 中, INGO 没有达到理论最优值, 可结果

明显优于其他算法, 更加趋近于理论最优解。在多峰函数中, INGO 同样表现出卓越的性能。在 F_7 上, 尽管 DBO 的表现不尽人意, 其所得结果与理论最优值存在显著差距, 虽然 INGO 求得的最优解不是最好的, 但是在适应度值上却显著优于其他对比算法。在 $F_8 \sim F_{10}$ 中, INGO 都达到理论最优值, 而 SSA 也达到理论最优值, 相较于其他算法, INGO 在最优值、平均值以及标准差上均展现出更为优越的表现。

而在固定维度多峰函数 $F_{11} \sim F_{14}$ 上 INGO 都能找到最优值,虽结果相差不大,但也遥遥领先于其他对比算法。

综上可知,INGO 的平均值和标准差是最小的,说明柯西变异改进策略是有效的,不仅扩大了种群的多样性还提升了算法的全局探索能力;INGO 具有更快的收敛速度和更优的收敛精度,说明 SABO

改进措施帮助算法跳出局部最优,加速全局的收敛速度。当然,最优个体引领和上下限值策略也不可忽略地为提高算法的搜索效率做出了贡献。INGO 表现稳定且优秀,具有良好的优化效果,而 NGO 在某些复杂函数上的表现不如 INGO。SABO、DBO、SSA 和 GJO 算法在某些函数上表现良好,但整体稳定性和性能不如 INGO。

表 3 6 种算法寻优结果对比 (100 维)

Table 3 Comparison of optimization results of 6 algorithms (100-dimensional)

函数	统计值	INGO	NGO	SABO	DBO	SSA	GJO
F_1	Best	0	5.33e-206	0	0	0	1.15e-229
	Mean	0	5.59e-201	0	9.02e-236	3.17e-103	4.09e-221
	Std	0	0	0	0	1.74e-102	0
F_2	Best	0	8.79e-106	5.91e-223	2.58e-160	4.04e-94	5.04e-125
	Mean	0	3.71e-103	2.19e-219	7.62e-118	2.74e-54	2.83e-121
	Std	0	7.99e-103	0	4.17e-117	1.06e-53	7.77e-121
F_3	Best	0	1.05e-98	5.54e-225	4.90e-276	3.35e-231	3.68e-132
	Mean	0	9.43e-92	5.75e-183	3.48e-176	1.96e-69	2.33e-114
	Std	0	4.58e-91	0	0	1.06e-68	1.24e-113
F_4	Best	0	1.25e-91	1.48e-173	1.92e-162	1.34e-155	1.44e-87
	Mean	0	4.50e-90	4.75e-170	3.35e-112	3.80e-38	2.64e-81
	Std	0	5.84e-90	0	1.71e-111	2.08e-37	9.36e-81
F_5	Best	0	0.05	5.99	0.22	1.34e-13	6.13
	Mean	0	0.24	7.19	3.98	9.54e-07	6.90
	Std	0	0.12	0.60	0.81	2.79e-06	0.76
F_6	Best	1.59e-06	5.51e-05	1.92e-06	4.60e-05	3.87e-05	5.05e-06
	Mean	2.33e-05	0.000 2	4.11e-05	0.000 6	0.000 3	8.79e-05
	Std	2.43e-05	9.09e-05	3.52e-05	0.000 4	0.000 3	9.65e-05
F_7	Best	-3 109.81	-3 854.26	-2 191.26	-4 189.73	-3 854.25	-3 321.01
	Mean	-2 957.24	-3 436.46	-1 810.75	-3 500.90	-3 217.45	-2 382.87
	Std	110.93	212.66	170.59	435.82	281.40	405.60
F_8	Best	4.44e-16	3.99e-15	3.99e-15	4.44e-16	4.44e-16	4.44e-16
	Mean	4.44e-16	3.99e-15	3.99e-15	5.63e-16	4.44e-16	3.76e-15
	Std	0	0	0	6.49e-16	0	9.01e-16
F_9	Best	4.71e-32	9.41e-32	0.000 4	4.83e-32	4.71e-32	3.596e-06
	Mean	4.71e-32	7.91e-27	0.04	3.47e-22	4.79e-32	0.04
	Std	1.67e-47	2.87e-26	0.06	1.90e-21	1.16e-33	0.02
F_{10}	Best	1.35e-32	7.84e-29	0.004	3.32e-32	1.35e-32	7.36e-06
	Mean	1.35e-32	0.002	0.17	0.03	1.53e-32	0.14
	Std	5.57e-48	0.004	0.20	0.04	3.59e-33	0.09

为了更生动地呈现数据可视化的效果,INGO 与 5 种对比算法在 30 维空间下对 14 个不同测试函数的收敛曲线,如图 2 所示。从图中的对比可以看出,INGO 在多种函数类型中的卓越表现。在单峰函数 F_1 、 F_3 中,INGO 可以快速收敛并获得非常好的适应度值,显著优于其他对比算法,SSA 也展现出很好的收敛能力,但收敛精度不如 INGO。在 F_2 、 F_4 和 F_5 中,INGO 不仅达到理论最优值,特别在 F_5 中,虽然其表现略逊于 SSA,但是整体上依然保持极高的收敛精度

和稳定性。对于 F_6 、 F_7 ,虽然未达到理论最优值的函数,INGO 依然实现快速的收敛,并且其收敛精度远高于其他 5 种对比算法,显示出强大的优化能力。在多峰函数 $F_8 \sim F_{10}$ 中,INGO 能够有效地跳出局部最优陷阱,持续向全局最优解逼近,展现其卓越的探索与利用平衡能力。特别是在固定维度的多峰函数 $F_{11} \sim F_{14}$ 中,INGO 在整个迭代过程中均保持出色的性能,不仅避免局部最优的困扰,还成功达到最优的适应度值,进一步验证其算法的有效性和鲁棒性。




图 2 各算法 30 维寻优对比曲线

Fig. 2 Comparison curves of optimization for various algorithms in 30-dimensional space

3.4 Wilcoxon 秩和检验分析

为了进一步细化算法性能的比较,本文采用 Wilcoxon 秩和检验这一非参数统计检验方法,用于评估实验结果,设定其显著性水平为 5%。具体而言,当计算得到的 p 值低于 5% 时,则可以断定两种算法之间在性能上存在显著的差异。在表 4 所示的数据中,SABO 在 F_1 中统计结果为 1,SSA 在 F_8 中统计结果为 1,SABO 和 SSA 与 INGO 均取得理论上的最优值,INGO 与 SABO、SSA 的性能表现相当,没有显著的差异。然而,对于其他测试函数而言,INGO 与其余 5 种算法的比较结果均显示出了 p 值小于 5% 的显著性差异,意味着 INGO 在这些测试函数上的性能与其他算法相比,存在显著差异。此外, p 值越小,表明这种差异越为显著,即 INGO 相对于其他算法的性能差异越加明显。

表 4 Wilcoxon 秩和检验结果
Table 4 Wilcoxon rank sum test results

	NGO	SABO	DBO	SSA	GJO
F_1	1.21e-12	1	1.21e-12	1.66e-11	1.21e-12
F_2	1.21e-12	1.21e-12	1.21e-12	1.21e-12	1.21e-12
F_3	1.21e-12	1.21e-12	1.21e-12	1.21e-12	1.21e-12
F_4	1.21e-12	1.21e-12	1.21e-12	1.21e-12	1.21e-12
F_5	1.21e-12	1.21e-12	1.21e-12	1.21e-12	1.21e-12
F_6	6.70e-11	0.03	5.49e-11	9.92e-11	3.16e-05
F_7	3.70e-11	3.02e-11	5.09e-08	9.79e-05	2.20e-07
F_8	1.69e-14	1.69e-14	0.33	1	7.15e-13
F_9	1.22e-12	1.21e-12	1.21e-12	2.07e-06	1.21e-12
F_{10}	1.20e-12	1.21e-12	1.19e-12	0.003	1.21e-12
F_{11}	1.21e-12	3.69e-11	1.25e-07	0.08	2.83e-08
F_{12}	3.01e-11	8.12e-07	3.37e-05	3.47e-10	0.91
F_{13}	5.77e-11	8.13e-11	1.63e-10	5.77e-11	0.000 9
F_{14}	7.35e-11	4.18e-09	0.001	1.76e-11	6.74e-06

3.5 INGO 算法的工程应用及结果分析

静压推力轴承设计问题^[24-26]是经典工程设计中的一个实际优化问题,其主要目标是通过优化 4 个设计变量来最小化轴承在运行中的功率损失,这些变量包括轴承半径 (R)、凹槽半径 (R_0)、润滑油粘度 (μ) 和润滑油流量 (Q),如图 3 所示。静压推力轴承设计问题的数学模型如下:

设计变量:

$X = [x_1, x_2, x_3, x_4] = [R, R_0, \mu, Q]$ (12)

变量取值范围:

$1 \leq x_1, x_2, x_4 \leq 16; 1 \times 10^{-6} \leq x_3 \leq 16 \times 10^{-6}$ (13)

目标函数为

$f_{\min}(x) = \frac{QP_0}{0.7} + E_f$ (14)

式中: Q 为润滑油流量, P_0 为入口油压, E_f 为摩擦造成的功率损失。

约束条件如下:

$$\begin{cases} g_1(x) = 1\,000 - P_0 \leq 0 \\ g_2(x) = W - 101\,000 \leq 0 \\ g_3(x) = 5\,000 - \frac{W}{\pi(R^2 - R_0^2)} \leq 0 \\ g_4(x) = 50 - P_0 \leq 0 \\ g_5(x) = 0.001 - \frac{0.030\,7}{386.4P_0} \left(\frac{Q}{2\pi Rh}\right) \leq 0 \\ g_6(x) = R - R_0 \leq 0 \\ g_7(x) = h - 0.001 \leq 0 \end{cases}$$
 (15)

$$\begin{cases} W = \frac{\pi P_0}{2} \frac{R^2 - R_0^2}{\ln(\frac{R}{R_0})} \\ P_0 = \frac{6\mu Q}{\pi h^3} \ln(\frac{R}{R_0}) \\ E_f = 9\,336Q \times 0.030\,7 \times 0.5\Delta T \\ \Delta T = 2(10^P - 559.7) \\ P = \frac{\log_{10}\log_{10}(8.122 \times 10^6\mu + 0.8) + 3.55}{10.04} \\ h = \left(\frac{2\pi \times 750}{60}\right)^2 \frac{2\pi\mu}{E_f} \left(\frac{R^4}{4} - \frac{R_0^4}{4}\right) \end{cases}$$
 (16)




图 3 静压推力轴承模型

Fig. 3 Hydrostatic thrust bearing model

使用 INGO 与前文 5 种算法进行对比,每种算法独立运行 30 次,静压推力轴承设计问题的收敛曲

线,如图 4 所示。从图中可以看出,INGO 在收敛精度与速度方面展现出显著的优势。具体而言,当迭代次数接近 40 次时,INGO 就开始稳定的收敛,这一表现明显优于其他对比算法。INGO 算法的收敛平均值、标准差和最优值均优于其他对比算法,展现其较高的收敛精度、较快的收敛速度以及稳定性。因此,INGO 在静压推力轴承设计问题上的综合表现最佳,证明其在处理此类优化问题时的高效性和可靠性,能够为工程师们提供更优质的设计方案和更高效的解决方案,见表 5。




图 4 各算法在静压推力轴承设计问题上的收敛曲线

Fig. 4 Convergence curves of various algorithms in the design of hydrostatic thrust bearings

表 5 各算法在静压推力轴承设计问题上优化结果							
Table 5 Optimization results of various algorithms in the design of hydrostatic thrust bearings							
算法	变量最优值				最优值	平均值	标准差
	x_1	x_2	x_3	x_4			
INGO	6. 01	5. 44	6. 11e-06	3. 04	1 727. 94	2 087. 94	155. 64
NGO	6. 06	5. 48	6. 86e-06	3. 88	1 995. 82	2 283. 78	396. 75
SABO	7. 12	6. 45	6. 47e-06	5. 40	2 587. 76	3 301. 94	605. 29
SSA	6. 53	6. 01	7. 64e-06	5. 98	1 985. 40	3 001. 85	595. 76
GJO	6. 09	5. 51	7. 02e-06	4. 23	2 226. 64	2 188. 77	318. 22

4 结束语

本文针对传统北方苍鹰算法在优化过程中面临收敛速度慢、收敛精度低以及易陷入局部最优等问题,提出了混合策略 INGO。通过引入最优个体引领策略、减法平均优化器、柯西变异和上下限值策略。将其与其他对比算法在 14 个基准测试函数及 Wilcoxon 秩和检验中进行寻优性能对比,实验结果表明,INGO 算法具有更快的收敛速度和更高的收敛精度。同时,通过解决静压推力轴承设计优化问题,验证 INGO 算法在工程实践中的可行性和实用性,为工程应用提供了坚实支撑。未来的研究重心将放在进一步提升算法性能上,并广泛拓展其在实际优化问题中的应用范围。

参考文献

[1] 康晓华. 基于改进布谷鸟搜索算法的电力系统多目标运行优化研究 [J]. 微型电脑应用, 2024, 40 (4): 218-220.

[2] 张鑫强,邱一卉,李若玉. 基于改进黏菌算法的特征选择方法 [J]. 厦门大学学报(自然科学版), 2024,63(3):550-561.

[3] 饶鑫. 基于改进蚁群算法的自动驾驶车辆路径规划 [D]. 沈阳: 沈阳建筑大学,2022.

[4] TROJOVSKY P, DEHGHANI M. Subtraction - average - based optimizer: A new swarm - inspired metaheuristic algorithm for

solving optimization problems [J]. Biomimetics, 2023, 8 (2): 149-191.

[5] CHOPRA N, ANSARI M M. Golden jackal optimization: A novel nature-inspired optimizer for engineering applications [J]. Expert Systems with Applications, 2022, 198: 116924.

[6] XUE J, SHEN B. A novel swarm intelligence optimization approach: Sparrow search algorithm [J]. Systems Science & Control Engineering, 2020, 8 (1): 22-34.

[7] XUE J, SHEN B. Dung beetle optimizer: A new meta-heuristic algorithm for global optimization [J]. The Journal of Supercomputing, 2023, 79 (7): 7305-7336.

[8] DEGHANI M, HUBALOVSKY S, TROJOVSKY P. Northern goshawk optimization: A new swarm-based algorithm for solving optimization problems [J]. IEEE Access, 2021, 9: 162059 - 162080.

[9] 倪金,索丽敏,刘海龙,等. 基于北方苍鹰优化核极限学习机的玉米品种鉴别研究 [J]. 光谱学与光谱分析, 2024, 44 (6): 1584-1590.

[10] CHANG T, GE Y, LIN Q, et al. Optimal configuration of hybrid energy storage capacity based on northern goshawk optimization [C]// Proceedings of the 35th Chinese Control and Decision Conference . 2023: 301-306.

[11] ZHONG J, CHEN T, YI L. Face expression recognition based on NGO-BILSTM model [J]. Frontiers in Neurorobotics, 2023, 17: 1155038.

[12] 全柯,朱良宽,王璟瑀,等. 多策略融合改进北方苍鹰算法的森林冠层图像分割 [J]. 森林工程,2024,40(5):124-133.

[13] 张轶钦,魏业文,谭林,等. 基于多策略改进 INGO 算法短期风速预测 [J/OL]. [2024-10-16]. <http://h-p.kns.cnki.net>.

shiep. vpn358. com/kcms/detail/11. 3724. tp. 20240906. 1148. 002. html.

[14]雷文静,何庆. 多策略协同优化的北方苍鹰优化算法及应用[J]. 智能计算机与应用, 2024, 14 (3): 28-36.

[15]徐碧阳,覃涛,魏巍,等. 基于多策略改进的蜜獾优化算法[J]. 小型微型计算机系统, 2024, 45 (3): 753-762.

[16]YAO X, LIU Y, LIN G. Evolutionary programming made faster[J]. IEEE Transactions on Evolutionary Computation, 1999, 3 (2): 82-102.

[17]朱兴淋,汪廷华,赖志勇. 混合策略改进的金豺优化算法[J]. 计算机工程与应用, 2024, 60 (4): 99-112.

[18]陈俊,何庆. 混合策略改进的麻雀优化算法[J]. 小型微型计算机系统, 2023, 44 (7): 1470-1478.

[19]孙仟硕,王英博. 融合多策略的改进蜣螂优化算法及其应用[J/OL]. [2024-10-16]. <http://doi.org.shiep.vpn358.com/10.13976/j.cnki.xk.2024.3194>.

[20]李琦,许素安. 基于 GSABO-BP 和 Bootstrap 的电力负荷区间预测[J]. 现代电子技术, 2024, 47 (10): 28-33.

[21]陈将宏,王羲沐,李伟亮,等. 采用改进北方苍鹰算法的微电网优化调度研究[J]. 重庆理工大学学报(自然科学), 2024, 38 (1): 281-289.

[22]李斌,郭自强,高鹏. 改进北方苍鹰算法在光伏阵列中应用研究[J]. 电子测量与仪器学报, 2023, 37 (7): 131-139.

[23]刘松林,高鹰,林锐灿,等. 混合策略改进的减法平均优化算法[J]. 智能计算机与应用,2024,14(8):70-77.

[24]RAO R V, SAVSANI V J, VAKHARIA D P. Teaching-learning-based optimization: A novel method for constrained mechanical design optimization problems[J]. Computer - Aided Design, 2011, 43(3): 303-315.

[25]KUMAR A, WU G, ALI M Z, et al. A test-suite of non-convex constrained optimization problems from the real-world and some baseline results[J]. Swarm and Evolutionary Computation, 2020, 56: 100693.

[26]张凯,赵如杰,张义民,等. 改进教与学算法的静压推力滑动轴承优化[J]. 机械设计与制造, 2024,398(4): 56-59.