

Harris Hawks Optimization Based on Chaotic Lens Imaging Learning and Its Application*

YIN Dexin¹, ZHANG Linna², ZHANG Damin^{1*}, CAI Pengchen¹, QIN Weina¹

(1. College of Big Data and Information Engineering, Guizhou University, Guiyang Guizhou 550025, China;

2. College of Mechanical Engineering, Guizhou University, Guiyang Guizhou 550025, China)

Abstract: Harris's Hawk algorithm (HHO) is difficult to strike a balance between exploration and development. It is easy to get into the problems of local optimum and low diversity of population. To solve these problems, a new Harris's Hawk algorithm based on chaotic Lens Imaging Learning (FLHHO) is proposed. First, it uses Fuch chaotic strategy to initialize the population and enrich the diversity of the population. Second, it uses golden sine strategy to improve the precision of the algorithm in the exploration phase. Finally, it uses hybrid lens imaging learning and Cauchy mutation strategy, the best position of the Harris's Hawk is disturbed to improve the ability of the algorithm to jump out of local optimum. The improved Harris's Hawk algorithm (FLHHO) is applied to 10 classical test functions and 29 CEC2017 test functions. The simulation results show that the FLHHO algorithm is superior to HHO algorithm, other improved HHO algorithm and other new algorithms. Meanwhile, FLHHO is applied to the industrial Internet of things to optimize spectrum allocation, and the energy efficiency is taken as the evaluation index. The experimental results show that the energy efficiency based on FLHHO algorithm is better than other algorithms, which verifies the feasibility of FLHHO application in practice.

Key words: industrial Internet of things; harris's hawk algorithm; Fuch chaotic strategy; golden sine strategy; lens imaging learning strategy; cauchy mutation

EEACC: 7230 doi: 10.3969/j.issn.1004-1699.2021.11.008

基于混沌透镜成像学习的哈里斯鹰算法及其应用*

尹德鑫¹, 张琳娜², 张达敏^{1*}, 蔡朋宸¹, 秦维娜¹

(1. 贵州大学大数据与信息工程学院, 贵州 贵阳 550025; 2. 贵州大学机械工程学院, 贵州 贵阳 550025)

摘要: 针对哈里斯鹰算法 (HHO) 很难在探索和开发之间取得平衡, 且易陷于局部最优和种群低多样性等问题, 本文提出一种基于混沌透镜成像学习的哈里斯鹰算法 (FLHHO)。首先, 利用 Fuch 无限折叠混沌策略初始化种群, 丰富种群多样性; 其次, 在探索阶段引入黄金正弦策略, 提高算法的求解精度; 最后, 利用混合透镜成像学习和柯西变异策略, 对哈里斯鹰最佳位置进行扰动, 提高算法跳出局部最优的能力。将改进后的哈里斯鹰算法 (FLHHO) 在 10 个经典测试函数和 29 个 CEC2017 测试函数上进行求解精度, 仿真结果表明, FLHHO 算法优于 HHO 算法、其他改进 HHO 算法和其他最新算法。同时, 将 FLHHO 应用到工业物联网中来优化频谱分配, 将能量效率作为评价指标, 实验结果表明基于 FLHHO 算法的能量效率优于其他算法, 验证了 FLHHO 应用到实际中的可行性。

关键词: 工业物联网; 哈里斯鹰算法; Fuch 混沌策略; 黄金正弦策略; 透镜成像学习策略; 柯西变异

中图分类号: TP18; TP212.9

文献标识码: A

文章编号: 1004-1699 (2021) 11-1463-12

优化是为特定问题的所有可行解决方案找到最佳解决方案的过程。数值优化经常应用到各种领域中来处理优化问题, 而群智能算法在解决优化问题中显示了高效且鲁棒的性能。每年都会出现大量新颖

的群体智能算法, 例如: 鲸鱼优化算法 (Whale Optimization Algorithm, WOA)^[1]、灰狼算法 (Grey Wolf Optimizer, GWO)^[2]、蜻蜓算法 (Dragonfly algorithm, DA)^[3]、绯鲢鲤优化算法 (Yellow Saddle Goatfish algo-

项目来源: 国家自然科学基金项目 (62062021, 61872034); 贵州省科学技术基金项目 (黔科合基础[2020]1Y254)

收稿日期: 2021-04-26 修改日期: 2021-07-23

rithm, YSGA)^[4] 和麻雀搜索算法 (Sparrow Search Algorithm, SSA)^[5] 等。2019 年, Heidari 等^[6] 通过模仿哈里斯鹰在猎物捕食过程中的合作行为提出一种新的群智能算法——哈里斯鹰算法 (Harris Hawks Optimization, HHO), HHO 算法操作简单, 调整参数少, 易于实现, 因此 HHO 算法常用来解决很多工程问题。但 HHO 算法和其他群体智能算法相似, 本身仍存在面对处理多维问题时求解精度不高, 易过早收敛等问题。针对这些问题, 一些学者以不同的方式对 HHO 算法进行改进。文献[7]提出一种新型准反射哈里斯鹰算法 (QRHHO), 它将 HHO 算法和基于准反射的学习机制 (QRBL) 相结合, 提高 HHO 算法的寻优精度; 文献[8]提出一种混沌哈里斯鹰优化算法 (CHHO), 将混沌映射来生成初始化种群, 增加种群多样性, 然后将模拟退火算法与 HHO 结合, 提高 HHO 的利用率且避免局部最优; 文献[9]将长期记忆引入到 HHO 算法中, 在整个搜索过程中增加种群多样性; 文献[10]提出将哈里斯鹰算法和模拟重复算法混合, 优化算法性能; 文献[11]提出一种基于自适应协作觅食和分散觅食策略的 HHO 算法, 有效丰富种群多样性, 防止局部过早收敛。

然而, 综上所述的改进算法在一定程度上提高了勘探能力, 避免过早收敛, 但是面对高维复杂问题易造成探索和开发之间的不平衡, 随着搜索空间维度增加收敛速度变慢。针对这些问题, 提出一种基于混沌透镜成像学习的哈里斯鹰算法 (FLHHO), 并将 FLHHO 应用到工业物联网领域。本文的主要贡献如下: ①利用 Fuch 无限折叠混沌策略生成初始种群, 有效改善种群多样性。②将黄金正弦算子引入到探索阶段位置更新处, 提高 HHO 的求解精度。③利用透镜成像学习和柯西变异策略对哈里斯鹰最佳位置进行扰动更新, 增强探索和开发之间的平衡能力, 避免局部最优。④利用标准测试函数和 CEC 2017 测试函数证明基于混沌透镜成像学习的哈里斯鹰算法 (FLHHO) 具有更优的算法性能。⑤将认知无线电技术应用到工业物联网传感器网络上, 利用 FLHHO 来解决工业物联网中频谱稀缺问题。

1 哈里斯鹰算法

哈里斯鹰算法 (HHO) 的灵感来自哈里斯鹰探索和攻击猎物的行为, HHO 由两个阶段 (即探索阶段和开发阶段) 组成, 并且哈里斯鹰根据猎物逃逸能量 E 来采取不同的捕捉策略捕食猎物, 能量 E 的计算公式如下所示:

$$E = 2E_0 \left(1 - \frac{t}{T} \right) \quad (1)$$

式中: $E_0 = 2r_1 - 1$ 表示能量的初始状态, 该状态在每次迭代期间以 $(-1, 1)$ 的间隔随机变化, r_1 为 $(0, 1)$ 中的随机数。 t 为当前的迭代次数, T 为最大迭代次数。当 $|E| \geq 1$ 时, 哈里斯鹰处于探索阶段, 与此相反, 哈里斯鹰处于开发阶段。

1.1 探索阶段

在探索阶段, 哈里斯鹰根据其他成员位置和兔子的位置随机栖息在一些地点的情况, 通过两种策略来寻找猎物。数学模型如下:

$$x_i(t+1) = \begin{cases} x_{\text{rand}} - r_1 |x_{\text{rand}} - 2r_2 x_i(t)| & q \geq 0.5 \\ (x_{\text{prey}}(t) - x_m(t)) - r_3 [lb_i + r_4 (ub_i - lb_i)] & q < 0.5 \end{cases} \quad (2)$$

$$x_m(t) = \frac{1}{N} \sum_{i=1}^N x_i(t) \quad (3)$$

式中: t 表示当前迭代次数, T 表示最大迭代次数, x_i 和 x_{rand} 分别表示第 i 只哈里斯鹰的当前位置和在当前迭代的随机个体, $x_m(t)$ 表示当前哈里斯鹰的平均值, $x_{\text{prey}}(t)$ 为当前最优位置, r_1, r_2, r_3 和 r_4 为 $[0, 1]$ 的随机数, lb_i 和 ub_i 为搜索空间的界限, N 表示种群数量。

1.2 开发阶段

在开发阶段, 猎物经常试图逃脱, 哈里斯鹰则会去追赶猎物并试图抓住它。因此, HHO 采用四种策略来模仿哈里斯鹰的捕食行为, 这四种策略分别是软包围、硬包围、渐进式快速俯冲的软包围和渐进式快速俯冲的硬包围。HHO 通过 r 和 $|E|$ 两个参数来确认使用哪种策略, $|E|$ 表示猎物逃逸能量, r 表示逃逸概率。

当 $|E| \geq 0.5$ 和 $r \geq 0.5$ 时, 猎物仍然有逃逸的能量, 此时, 鹰使用软包围捕食猎物以使其精疲力尽, 从而使鹰可以突击突袭, 数学建模如下:

$$x(t+1) = \Delta x - E |J x_{\text{prey}}(t) - x(t)| \quad (4)$$

$$\Delta x(t) = x_{\text{prey}}(t) - x(t) \quad (5)$$

$$J = 2(1 - r_6) \quad (6)$$

式中: $\Delta x(t)$ 表示猎物位置和迭代 t 中当前位置之间的差值, r_6 为 $(0, 1)$ 内的随机数, J 表示兔子逃逸过程中的跳跃距离。

当 $|E| < 0.5$ 和 $r \geq 0.5$ 时, 猎物没有逃逸的能量, 哈里斯鹰使用硬包围捕食猎物以进行最后突击突袭, 数学建模如下:

$$x(t+1) = x_{\text{prey}}(t) - E |\Delta x(t)| \quad (7)$$

当 $|E| \geq 0.5$ 且 $r < 0.5$ 时, 猎物有足够能量逃脱鹰的捕捉, 但是哈里斯鹰会围绕猎物进行渐进式快

速俯冲软包围,并根据猎物的欺骗性行为逐渐纠正其位置和方向,从而选择最佳位置来捕捉猎物,哈里斯鹰的位置更新分为两种策略。在第一种策略中,哈里斯鹰根据猎物的下一步移动向猎物靠近,位置更新如下所示:

$$Y = x_{\text{prey}}(t) - E |J x_{\text{prey}}(t) - x(t)| \quad (8)$$

在第二种策略中,鹰看到猎物逃跑,它们就会做出更具欺骗性的动作,并且在接近猎物时会进行不规则的快速下潜。为了模仿猎物的逃逸行为,在优化过程中引入了 Levy 飞行,其位置更新公式如下所示:

$$Z = Y + S \text{Levy}(D) \quad (9)$$

$$\text{Levy}(x) = 0.01 \times \frac{u\sigma}{|v|^{\frac{1}{\beta}}} \quad (10)$$

$$\sigma = \left\{ \frac{\Gamma(1+\beta) \sin(\pi\beta/2)}{\Gamma[(1+\lambda)/2] \beta \times 2^{(\beta-1)/2}} \right\}^{1/\beta} \quad (11)$$

式中: D 为问题维度, S 表示为 $1 \times D$ 的随机向量,Levy 表示飞行函数,计算公式如 (10) 所示, β 为常数设置为 1.5, u 和 v 为 $[0, 1]$ 内的随机数。因此,渐进式快速俯冲的软包围策略的位置更新公式总结为:

$$x(t+1) = \begin{cases} Y & F(Y) > F[x(t)] \\ Z & F(Z) < F[x(t)] \end{cases} \quad (12)$$

式中: $F(Y)$ 和 $F(Z)$ 为目标函数值。

当 $|E| < 0.5$ 且 $r < 0.5$ 时,猎物筋疲力尽,逃逸能量很低,哈里斯鹰通过渐进式俯冲硬包围猎物,此策略鹰的更新位置公式与渐进式快速俯冲的软包围中的公式相似。在这种情况下,鹰群尝试缩小其平均位置与目标兔子的位置之间的距离,数学建模如下:

$$x(t+1) = \begin{cases} Y & F(Y) < F[x(t)] \\ Z & F(Z) < F[x(t)] \end{cases} \quad (13)$$

$$Y = x_{\text{prey}}(t) - E |J x_{\text{prey}}(t) - x_m(t)| \quad (14)$$

$$Z = Y + S \text{Levy}(D) \quad (15)$$

2 基于混沌透镜成像学习的哈里斯鹰算法

2.1 Fuch 无限折叠混沌策略

初始值对算法影响很大,如果初始值很大,算法将更耗时且容易陷入局部最优。如果初始值接近全局最优解,则算法收敛很快。因为 HHO 并无先验知识可用,故通常采用随机生成初始种群,生成的种群分布不均匀,会导致种群多样性减少,种群质量不高,影响算法的收敛速度。而混沌映射具有随机性、非重复性和混沌遍历性等特点^[12],意味着它比依赖于概率的随机生成更能够使种群分布均匀。因此,利用混沌映射生成初始种群来增加潜在解的多样性。

常用的混沌映射有 Tent 映射和 Logistic 映射,

但是两者都为有限折叠混沌映射。Fuch^[13] 为可无限折叠的混沌映射,比起传统的混沌映射,Fuch 映射具有更佳的遍历性、动态性和收敛性等优点,因此,选用 Fuch 映射生成 HHO 初始种群。在 FLHHO 算法中,Fuch 混沌映射值替换随机生成的值,用于在初始化阶段生成哈里斯鹰种群位置。Fuch 混沌映射数学表达式为^[14]:

$$x(t+1) = \cos \left[\frac{1}{x(t)^2} \right] \quad (16)$$

式中: $x(t) \neq 0, x \in Z^+, t = 1, 2, \dots, T_0$ 。

2.2 黄金正弦策略

受到正弦函数周期性变化的启发,Erkan Tanyildizi 在 2017 年提出黄金正弦算法^[15] (Golden-SA),利用正弦函数结合黄金分割系数来执行迭代搜索,该算法具有良好的鲁棒性和收敛速度。

在 HHO 探索阶段中采用随机游走的方式进行位置更新,搜索空间比较广泛,并不能确保鹰群可以完整探索最佳搜索空间区域。于是本文将黄金正弦算子引入到 HHO 探索阶段位置更新中,利用黄金分割搜索使搜索空间的个体能够按最优路径搜索,如图 1 所示为种群个体搜索空间的运动轨迹图,个体可以在搜索空间中连续寻找最优解,Golden-SA 可以根据正弦函数和单位圆之间的关系遍历正弦函数上的所有值从而提高了算法的全局探索能力^[16]。同时,黄金分割系数使搜索个体能够以固定的步长更新距离和方向,并不断缩小要探索的空间,以便个体能在目标位置的区域(而不是整个搜索空间)中进行搜索,从而提高了算法的局部开发能力。

$$x_i(t+1) = \begin{cases} x(t) \times |\sin(R_1)| + R_2 \sin(R_1) \times \\ |x_1 x_{\text{prey}}(t) - x_2 x(t)| & q \geq 0.5 \\ [x_{\text{prey}}(t) - x_m(t)] - r_3 [lb_i + r_4(ub_i - lb_i)] & q < 0.5 \end{cases} \quad (17)$$

式中: $R_1 \in [0, 2\pi], R_2 \in [0, \pi], x_1 = -\pi + (1 - \tau)$ 和 $x_2 = -\pi + (\tau \times 2\pi)$ 是通过黄金比率计算的系数,可以使个体搜索空间时更接近目标值, $\tau = (1 - \sqrt{5})/2$ 为黄金分割系数。




图 1 种群个体运动轨迹图

2.3 融合透镜成像学习和柯西变异策略

在原始的 HHO 中,目标位置的更新依赖于每次迭代时种群的更新,重新计算适应度值,选择最优适应度值个体代替当前个体,未考虑 HHO 会陷入局部最优的情境,针对这类问题,融合透镜成像学习和柯西变异策略,依概率对目标位置进行扰动更新,减少 HHO 陷入局部极值的风险。

反向学习是 Tizhoosh 于 2005 年提出^[17],其主要思想是生成可行解的相反解,评价相反解并选择更好的候选解。反向学习可以扩展当前哈里斯鹰的搜索范围,并且反向解可以更接近全局最佳位置,因此反向学习策略可以加快收敛速度。

定义 1 反向数:假设 x 是 $[a, b]$ 中的实数,则 x 的反向数 x^* 定义为:

$$x^* = a + b - x \quad (18)$$

定义 2 反向点:假设 $\mathbf{X} = (x_1, x_2, \dots, x_D)$ 为 D 维空间的一点,且 $x_j \in [a_j, b_j], j \in 1, 2, \dots, D$ 。则 $\mathbf{X}$ 的反向点可以定义为 $\mathbf{X}^* = (x_1^*, x_2^*, \dots, x_n^*)$,其中 $x_j^* = a_j + b_j - x_j$ 。

反向学习策略虽然在种群初始化中起到重要作用,但是在迭代后期,大量的个体会聚集在局部最优值周围,导致哈里斯鹰陷入局部最优陷阱,削弱反向学习策略作用。受到文献[18]的启发,利用透镜成像原理对反向学习策略进行扩展来解决上诉问题。

假设哈里斯鹰在搜索空间中寻找目标值反向点的过程为透镜成像的过程,如图 2 所示,在一个横坐标区间为 $[a, b]$ 上的 x_{best} 处高度为 h 的物体,通过在原点 $o(o = (a+b)/2)$ 处焦距为 r 的透镜投影到高度为 h' 处成像。此时, x_{best} 就能以 o 为基点找到对应的反向点 x_{best}^* 。由成像原理得出以下公式:

$$\frac{(a+b)/2 - x_{\text{best}}}{x_{\text{best}}^* - (a+b)/2} = k \quad (19)$$

$$\frac{r}{x_{\text{best}}^* - (a+b)/2 - r} = k \quad (20)$$

式中: $k = h/h'$ 为缩放因子,利用式(19)变换可得到反向点 x_{best}^* 的计算公式:

$$x_{\text{best}}^* = \frac{a+b}{2} + \frac{a+b}{2k} - \frac{x}{k} \quad (21)$$

可以很明显从式(20)看出,当 $k=1$ 时,透镜成像反向学习策略就是一般的反向学习策略,透镜成




图 2 透镜成像过程图

像学习策略的反向点随着 k 的变化而变化,可以通过调节 k 值来寻找最优位置,将透镜成像学习策略引入到哈里斯鹰目标位置更新中,以提高收敛速度,使哈里斯鹰摆脱陷入局部最优的风险,使算法有更大的机会收敛于全局最优解。

柯西变异源自于柯西分布,是一个数学期望不存在的连续性概率分布,其概率密度函数为:

$$f(x) = \frac{1}{\pi} \times \frac{1}{1+x^2} \quad (22)$$

柯西分布具有较长的步长、两端具有较长的尾巴和分布紧凑等特点^[19]。因此,很容易从原点生成随机数,并且它能产生比高斯变异更大的范围分布随机数。将柯西算子引入目标位置更新,发挥柯西算子的调节能力,增强算法跳出局部最优的能力:

$$x(t+1) = \text{cauchy}(0, 1) \oplus x_{\text{best}}(t) + x_{\text{best}}(t) \quad (23)$$

为了提高 HHO 的寻优性能,FLHHO 采取动态选择策略来更新目标位置,在一定的概率 pr 下交替选择透镜成像学习策略和柯西变异策略来更新目标位置。

$$\text{pr} = 0.4 \exp(-t/T) \quad (24)$$

pr 是随迭代自适应更改的参数,利用概率 pr 选择不同策略更新目标位置。在迭代早期阶段 pr 相对较大,此时 $\text{pr} > \text{rand}$,利用式(23)对目标位置进行柯西扰动,有效避免种群多样性下降和过早收敛。提高 HHO 从局部最佳位置逃出的能力。当 $\text{pr} < \text{rand}$ 时,对目标位置选择式(21)透镜成像学习策略进行更新,扩大 HHO 搜索范围,以较快的速度完成全局搜索,提高算法寻优精度。

2.4 FLHHO 算法复杂度分析

FLHHO 算法和 HHO 算法的复杂度与种群数量 N 、空间维度 D 和迭代次数 T 有关。HHO 算法的计算复杂度通过种群初始化、适应度值计算和种群更新三个基本过程来表示,那么 HHO 算法复杂度的计算如下所示:①在初始化阶段,初始并分配 N 只哈里斯鹰的值,计算复杂度为 $O(N)$;②计算哈里斯鹰最佳适应度值复杂度为 $O(TN)$;③在种群更新阶段,计算哈里斯鹰位置更新时算法的复杂度为 $O(TND)$ 。

由此可得 HHO 算法的时间复杂度为:

$$O(\text{HHO}) = O(N) + O(TN) + O(TND) = O(TND) \quad (25)$$

HHO 初始化种群阶段的复杂度和 FLHHO 一样,且引入黄金正弦策略的探索阶段和原探索阶段的计算复杂度几乎相同,计算采用动态策略对哈里斯鹰目标位置更新的复杂度为 $O(TND) + O(TND)$,故 FLHHO 的复杂度计算如下所示:

$$O(\text{FLHHO}) = O(N) + O(TN) + O(TND) + O(TND) = O(TND) \quad (26)$$

根据以上分析,FLHHO 和 HHO 具有相同的复杂度,FLHHO 算法增加了全局和局部搜索能力,但是没有增加时间复杂度。

3 仿真实验与结果分析

为了验证 FLHHO 算法的优越性和每个改进策略的有效性,本文选取 10 个常用的标准测试函数和最新的测试函数 IEEE CEC 2017^[20] 来进行测试。本文仿真实验分为 5 个部分:①通过标准测试函数验证三种改进策略对改进 HHO 的有效性。②将 FLHHO 与最新改进的 HHO 进行比较,通过标准测试函数测试数据证明 FLHHO 的算法性能优于其他改进算法。③将 FLHHO 算法与其他群体智能算法进行比较,通过实验数据验证 FLHHO 的优越性。④将 FLHHO 算法与其他群体智能算法进行 Wilcoxon 秩和检验,检验 FLHHO 与其他算法的显著性差异。⑤将 FLHHO 算法求解 CEC 2017 测试函数,并与其他群体智能算法比较,证明 FLHHO 算法的鲁棒性。

本文引入 10 个标准测试函数,如表 1 所示,标准测试函数分为单峰函数、多峰和固定低维函数。其中 F1~F7 为单峰函数,仅具有一个最优值,通常用于测试算法的开发能力;F8~F13 是多峰函数,具有多个最优值,将其用于测试探索能力和跳出局部最优能力,F14 为固定低维函数,其也有多个的最优值。但是,由于维数低,很容易找到最优值,因此可以用来测试算法的稳定性。

表 1 标准测试函数

函数	维度	搜索范围	最小值
F1 Sphere	30	$[-100, 100]$	0
F2 Schwefel 2.22	30	$[-10, 10]$	0
F3 Schwefel 1.2	30	$[-100, 100]$	0
F4 Schwefel 2.21	30	$[-100, 100]$	0
F7 Quartic	30	$[-1.28, 1.28]$	0
F8 Schwefel 2.26	30	$[-500, 500]$	$-418.982\ 9 \times D$
F10 Ackley	30	$[-32, 32]$	0
F11 Griewank	30	$[-600, 600]$	0
F13 Penalized	30	$[-50, 50]$	0
F14 Foxholes	30	$[-65.56, 65.56]$	0.998

为了公平起见,在本文中,所有算法都具有相同的条件以进行公平比较,最大迭代次数 T 设置为 500,种群数量 N 设置为 30,每种算法独立运行 30 次,具体参数设置参照各算法引用文献。

3.1 与不同改进策略比较

利用 FLHHO 求解表 1 中的测试函数,并与结

合 Fuch 混沌策略的 HHO1、引入黄金正弦策略的 HHO2 和融合透镜成像学习和柯西变异策略的 HHO3 进行比较,测试结果如表 2 所示(测试维度 $D=30$)。

表 2 测试函数比较结果(维度 $D=30$)

函数	算法	最优值	平均值	标准差
F1	FLHHO	0.00E+00	0.00E+00	0.00E+00
	HHO	3.60E-101	1.22E-96	3.59E-95
	HHO1	1.67E-102	1.75E-98	2.19E-98
	HHO2	9.10E-108	1.17E-101	2.03E-101
	HHO3	0.00E+00	0.00E+00	0.00E+00
F2	FLHHO	0.00E+00	0.00E+00	0.00E+00
	HHO	5.29E-57	4.22E-49	2.31E-48
	HHO1	9.41E-55	3.44E-53	2.88E-53
	HHO2	1.69E-58	1.25E-50	4.73E-50
	HHO3	0.00E+00	0.00E+00	0.00E+00
F3	FLHHO	0.00E+00	0.00E+00	0.00E+00
	HHO	3.27E-98	5.04E-73	2.79E-72
	HHO1	1.52E-90	4.52E-79	7.86E-79
	HHO2	2.46E-96	1.49E-73	3.55E-73
	HHO3	0.00E+00	0.00E+00	0.00E+00
F4	FLHHO	0.00E+00	0.00E+00	0.00E+00
	HHO	1.31E-56	6.34E-50	1.77E-49
	HHO1	3.18E-54	1.63E-49	3.06E-49
	HHO2	9.42E-55	1.49E-43	6.47E-43
	HHO3	0.00E+00	0.00E+00	0.00E+00
F7	FLHHO	1.06E-07	3.76588E-05	4.74E-05
	HHO	3.10E-06	1.91E-04	2.22E-04
	HHO1	1.66E-05	1.52E-04	1.29E-04
	HHO2	2.11E-05	9.61E-05	6.41E-05
	HHO3	4.68E-06	3.69E-05	3.78E-05
F8	FLHHO	-1.26E+04	-1.26E+04	2.75E-04
	HHO	-1.26E+04	-1.26E+04	7.22E-01
	HHO1	-1.26E+04	-1.26E+04	9.84E-03
	HHO2	-1.26E+04	-1.26E+04	6.74E-03
	HHO3	-1.26E+04	-1.26E+04	2.97E-01
F10	FLHHO	8.88E-16	8.88E-16	0.00E+00
	HHO	8.88E-16	8.88E-16	0.00E+00
	HHO1	8.88E-16	8.88E-16	0.00E+00
	HHO2	8.88E-16	8.88E-16	0.00E+00
	HHO3	8.88E-16	8.88E-16	0.00E+00
F11	FLHHO	0.00E+00	0.00E+00	0.00E+00
	HHO	0.00E+00	0.00E+00	0.00E+00
	HHO1	0.00E+00	0.00E+00	0.00E+00
	HHO2	0.00E+00	0.00E+00	0.00E+00
	HHO3	0.00E+00	0.00E+00	0.00E+00
F13	FLHHO	7.82E-10	1.51E-08	2.03E-08
	HHO	1.37E-07	1.32E-04	2.49E-04
	HHO1	3.94E-09	5.55E-08	5.16E-08
	HHO2	5.43E-06	1.70E-05	3.31E-05
	HHO3	7.65E-07	6.40E-06	6.13E-06
F14	FLHHO	9.98E-01	9.98E-01	0.00E+00
	HHO	9.98E-01	1.39E-01	9.56E-01
	HHO1	9.98E-01	9.98E-01	0.00E+00
	HHO2	9.98E-01	1.06E-01	2.25E-03
	HHO3	9.98E-01	9.98E-01	0.00E+00

因为单峰函数只有一个全局最优解,而没有其他局部最优解存在,可用于分析优化算法的开发能力。从表 2 可以清楚地知道 FLHH 求解单峰函数 F1~F4 时,最优值、平均值和标准差都达到理想值。虽然求解单峰函数 F7 没有达到理想值,但 F7 的其他指标都优于 HHO、HHO1、HHO2 和 HHO3。与单峰测试函数相比,多峰测试函数具有许多最优解,其中一个全局的,其余的是局部的,这些多峰测试问题通常用于评估算法的探索能力。可以从表 2 多峰函数 F8、F10、F11 和 F13 中的数据看出,对于函数 F8,四种算法的结果非常接近,但是可以从标准差方面看出 FLHHO 的稳定性略高于其他四种算法。对于函数 F10 和 F11,每种算法都可以获得理论上的最优解。对于函数 F13,FLHHO 拥有更高的寻优精度和稳定性。F14 是固定峰函数,可用于测试算法的稳定性和探索能力。对于求解固定峰函数 F14,FLHHO 的寻优性能全面超越了 HHO,并且求解结果与理论值非常接近。

可以从表 2 的三个评估指标看出,与 HHO 相比,对于求解单峰函数 F1~F4,基于透镜成像学习与柯西变异策略的 HHO3 改进效果非常显著,它可以准确地获得理论上的最佳值,HHO1 和 HHO2 相对来说,改进效果较弱。HHO3 求解 F7 时,虽然没有达到最优值,但是它的三个评估指标都优于 HHO、HHO1 和 HHO2,并且 HHO3 的稳定性优于 FLHHO,这说明透镜成像学习与柯西变异策略可以有效提高算法最佳搜索性能。HHO1 对于求解单峰函数的效果不如其他策略,但是对于求解多峰函数 F13,HHO1 的最优值、平均值和标准差明显优于其他算法,这说明在探索能力上具有优异的性能,这归因于哈里斯鹰的 Fuch 混沌策略提供了较高的种群多样性。表 2 评价指标证明了无论在单峰函数还是多峰函数中,融合 3 个改进策略的 FLHHO 具有更好的开发能力和探索能力。

3.2 与不同改进 HHO 算法的比较分析

为了进一步验证 FLHHO 算法的优越性,将 FLHHO 独立运行 30 次求解标准测试函数的结果同基于准反射哈里斯鹰算法^[7](QRHHO)、改进的哈里斯鹰算法^[21](MHHO)和混合差分算法的哈里斯鹰算法^[22](HHODE)相比。设置每种算法的共同参数最大迭代次数 $T=500$ 、种群规模 $N=30$ 、空间维度 $D=100$ 。求解部分基本测试函数,并将各个算法的最优值、平均值和标准差作为评价指标,结果分析如表 3 所示。

表 3 测试函数比较结果(维度 $D=100$)

函数	指标	FLHHO	QRHHO	MHHO	HHODE
F1	平均值	0.00E+00	0.00E+00	1.76E-125	6.45E-177
	标准差	0.00E+00	0.00E+00	5.89E-127	0.00E+00
F2	平均值	0.00E+00	5.03E-253	1.38E-61	3.27E-93
	标准差	0.00E+00	0.00E+00	7.29E-61	1.28E-92
F3	平均值	0.00E+00	0.00E+00	3.86E-95	4.60E-119
	标准差	0.00E+00	0.00E+00	2.08E-94	2.53E-118
F4	平均值	0.00E+00	2.04E-233	2.70E-77	1.82E-86
	标准差	0.00E+00	0.00E+00	1.01E-76	9.92E-86
F7	平均值	1.56E-05	8.86E-05	4.00E-02	1.61E-04
	标准差	1.01E-05	8.12E-05	2.60E-02	1.74E-04
F10	平均值	8.88E-16	8.88E-16	8.88E-16	8.88E-16
	标准差	0.00E+00	0.00E+00	0.00E+00	0.00E+00
F11	平均值	0.00E+00	0.00E+00	0.00E+00	0.00E+00
	标准差	0.00E+00	0.00E+00	0.00E+00	0.00E+00
F13	平均值	4.31E-08	5.69E-03	1.61E-05	1.06E-04
	标准差	4.89E-08	2.11E-03	4.34E-05	2.63E-04

可以从表 3 可以看出,相比其他改进算法,FLHHO 在求解高维测试函数上具有出色的寻优性能。QRHHO 和 FLHHO 一样,在求解单峰函数 F1~F4 时,近乎都能获得理论上的最优解,并且以压倒性的优势高于其他两种改进算法,MHHO 在求解单峰函数方面上算法性能最差。对于求解函数 F7,MHHO 的寻优性能最差,HHODE 次之,FLHHO 的寻优精度最优,但和 QRHHO 相差不大。对于求解函数 F10 和 F11,所有函数都能获得理论值,这主要是由于 HHO 已经为这些函数提供了最优结果。

在求解多峰函数 F13 上,FLHHO 的寻优精度最高,避免算法获得局部极值。QRHHO、MHHO 和 HHODE 在求解多峰函数 F13 时,所获得的寻优值远不如 FLHHO,特别是 QRHHO 在求解多峰函数 F13 时易陷于局部最优解,寻优性能最差。不管是求解单峰函数还是多峰函数,相比其他改进 HHO 算法,FLHHO 获得更高的求解精度和稳定性,这进一步说明了 FLHHO 改进策略的优越性。

3.3 与其他群智能算法的对比分析

将 FLHHO 与 HHO^[6]、鲸鱼算法^[1](WOA)、自适应灰狼算法^[23](IGWO)和麻雀搜索算法^[5](SSA)进行比较。为了显示公平性,将各算法的迭代次数 T 设置为 500,种群数量 N 设置为 30,算法空间维度 D 为 30。各算法在函数 F1~F4、F7~F8 和 F13 上的收敛曲线对比图如图 3~图 9 示。FLHHO 算法在求解大多数函数上均表现出色,其收敛速度远远优于其他群智能算法和 HHO,特别是在求解单峰函数上,HHO 和其他算法还未收敛时,FLHHO 就迅速找到理论上的最优值。我们可以从图 7 看出,各算法在求解 F7 时,都未能达到理想值,但 FLHHO 的寻

优精度最高且收敛速度最快,HHO 次之,IGWO 的寻优精度最低,SSA 的收敛速度最慢。




图 3 F1 收敛曲线图




图 4 F2 收敛曲线图




图 5 F3 收敛曲线图




图 6 F4 收敛曲线图




图 7 F7 收敛曲线图




图 8 F8 收敛曲线图




图 9 F13 收敛曲线图

此外,从图 8 可以看出,FLHHO 在求解多峰函数 F8 方面取得了较快的收敛速度,但其求解精度和 HHO 大致相同。从图 9 的多峰函数 F13 收敛曲线可以看出,FLHHO 在解决复杂问题方面上的效果明显优于其他算法,虽然可能会陷入局部最优状态,但可以看出,新提出的 FLHHO 的求解精度和收敛速度都高于其他算法。FLHHO 在一些函数上远远优于原始的 HHO,因为它实现了特别高的求解精度和求解速度。这些曲线进一步说明了本文提出的 FLHHO 算法的有效性。

3.4 Wilcoxon 秩和检验

Wilcoxon 秩和检验是一种非参数统计检验方法,本文使用 Wilcoxon 秩和检验来比较 ISSA 算法与 HHO、MHHO、HHODE、IGWO 和 SSA 算法之间是否有显著性区别的差异。表 4 列出了 Wilcoxon 秩和检验的统计结果,当检验结果 $P < 0.05$ 时,结果判断 S 用“+”表明 FLHHO 的结果有明显改善,显著性高于其他算法;当检验结果 $P > 0.05$ 时, S 用“-”表明 FLHHO 的结果较差,无法进行显著性判断时 S 用“=”表示。

秩和检验测试是基于 30 次独立运行进行的,每次运行最多进行 300 次迭代,可以从表 4 明显看出,FLHHO 算法除了与 HHO 算法、MHHO 算法和 HHODE 在 F10 函数和 F11 函数上无法进行显著性判断外,对于其他算法不管是在单峰函数和多峰函数上的检验结果,结果判断 S 都为+。这说明相比 HHO、MHHO、HHODE、IGWO 和 SSA,FLHHO 更具有显著性优势。

表 4 Wilcoxon 秩和检验结果

函数	FLHHO/HHO		FLHHO/MHHO		FLHHO/HHODE		FLHHO/IGWO		FLHHO/SSA	
	P	S	P	S	P	S	P	S	P	S
F1	1.01e-12	+	8.36e-08	+	2.95e-08	+	1.73e-08	+	1.73e-08	+
F2	1.01e-12	+	8.36e-08	+	2.95e-08	+	1.73e-08	+	1.73e-08	+
F3	1.01e-12	+	8.36e-08	+	2.95e-08	+	1.73e-08	+	1.73e-08	+
F4	1.01e-12	+	8.36e-08	+	2.95e-08	+	1.73e-08	+	1.73e-08	+
F7	1.01e-12	+	8.36e-08	+	2.95e-08	+	1.73e-08	+	1.73e-08	+
F10	NaN	=	NaN	=	NaN	=	1.73e-08	+	1.73e-08	+
F11	NaN	=	NaN	=	NaN	=	NaN	=	NaN	=
F13	1.01e-12	+	8.36e-08	+	2.95e-08	+	1.73e-08	+	1.73e-08	+

3.5 求解 CEC 2017 函数测试问题

CEC2017 是最新的基准函数集,包括单峰函数、简单多峰函数、混合函数和组合函数^[20]。其中 F1~F3 为单峰函数,F4~F10 为简单多峰函数,F11~F20 为混合函数,F21~F30 为组合函数。参

数详细信息见文献[20]。通过求解 C2017,将 FLHHO 与 HHO、鲸鱼算法^[1](WOA)、自适应灰狼算法^[23](IGWO)和麻雀搜索算法^[5](SSA)的测试结果进行比较,测试结果如表 5 所示(空间维度 $D=30$)。

表 5 CEC2017 测试函数的性能比较

函数	指标	FLHHO	HHO	WOA	IGWO	SSA
F1	平均值	4.04E+06	2.46E+09	4.61E+10	2.93E+07	2.62E+08
	标准差	2.16E+06	5.01E+09	1.16E+10	4.93E+07	1.35E+08
	排名	1	4	5	3	2
F3	平均值	6.25E+03	5.75E+04	2.22E+06	1.84E+04	4.38E+05
	标准差	6.00E+02	7.13E+03	3.33E+06	3.46E+03	4.68E+05
	排名	1	3	5	2	4
F4	平均值	6.13E+02	7.24E+03	1.43E+03	5.03E+02	4.93E+02
	标准差	2.57E+02	9.19E+02	2.95E+02	1.71E+02	1.92E+01
	排名	3	5	4	1	2
F5	平均值	2.18E+03	6.64E+03	8.75E+03	5.72E+03	7.45E+03
	标准差	3.23E+03	4.23E+03	8.01E+02	1.91E+02	5.81E+02
	排名	1	3	5	2	4
F6	平均值	5.75E+02	7.75E+03	6.78E+02	7.02E+02	6.57E+02
	标准差	2.70E+01	2.88E+02	7.41E+02	1.11E+02	4.01E+02
	排名	1	5	3	4	2
F7	平均值	3.41E+02	1.32E+03	1.09E+03	8.66E+02	1.22E+03
	标准差	5.20E+01	8.32E+02	5.75E+02	7.14E+02	9.1E+01
	排名	1	5	3	2	4
F8	平均值	5.23E+02	9.86E+02	1.09E+03	8.91E+02	9.91E+03
	标准差	3.32E+02	1.72E+02	5.71E+02	4.74E+02	2.91E+01
	排名	1	3	4	2	5
F9	平均值	9.71E+02	8.84E+03	9.36E+03	1.14E+03	5.06E+03
	标准差	2.83E+02	8.66E+02	1.83E+03	3.32E+03	5.09E+02
	排名	1	4	5	2	3
F10	平均值	1.23E+03	5.91E+03	7.23E+03	8.12E+03	5.21E+03
	标准差	5.09E+02	7.36E+02	2.31E+02	3.36E+03	5.997E+02
	排名	1	3	4	5	2
F11	平均值	1.50E+03	1.61E+03	8.11E+03	2.23E+03	1.29E+03
	标准差	2.31E+02	1.21E+03	2.61E+03	2.91E+02	5.13E+01
	排名	2	3	5	4	1
F12	平均值	4.28E+04	5.88E+07	3.91E+08	4.86E+06	1.18E+06
	标准差	2.26E+04	5.62E+07	1.74E+08	4.14E+06	8.26E+05
	排名	1	4	5	3	2
F13	平均值	5.04E+04	1.04E+06	6.75E+06	1.91E+05	2.38E+05
	标准差	2.78E+04	4.44E+05	3.59E+06	7.29E+04	1.92E+05
	排名	1	4	5	2	3

续表 5

函数	指标	FLHHO	HHO	WOA	IGWO	SSA
F14	平均值	7.33E+05	1.03E+06	3.54E+06	1.35E+04	4.57E+04
	标准差	5.29E+05	6.75E+05	1.94E+06	8.76E+03	3.51E+04
	排名	3	4	5	1	2
F15	平均值	1.31E+05	1.24E+05	3.65E+06	6.04E+04	1.87E+04
	标准差	2.43E+04	5.43E+04	2.86E+06	4.06E+04	1.47E+04
	排名	2	1	5	4	3
F16	平均值	3.87E+03	4.86E+03	4.29E+03	2.36E+03	3.18E+03
	标准差	3.80E+02	2.88E+03	4.63E+02	4.11E+02	3.94E+02
	排名	3	5	4	1	2
F17	平均值	2.61E+03	2.72E+03	2.83E+03	1.90E+03	2.38E+03
	标准差	2.98E+02	3.78E+02	4.33E+02	1.17E+02	3.86E+02
	排名	2	4	5	1	3
F18	平均值	2.52E+06	7.47E+06	6.51E+06	4.56E+05	7.81E+05
	标准差	2.94E+06	8.92E+06	4.91E+06	2.91E+05	9.26E+05
	排名	1	3	4	2	5
F19	平均值	1.91E+06	2.31E+06	2.22E+08	1.91E+04	6.31E+03
	标准差	8.82E+05	1.98E+06	1.91E+08	1.36E+04	3.46E+03
	排名	3	4	5	2	1
F20	平均值	1.22E+03	5.89E+03	2.91E+03	2.21E+03	2.76E+03
	标准差	1.45E+02	2.27E+02	2.31E+02	1.31E+02	2.03E+03
	排名	1	5	4	2	3
F21	平均值	2.61E+03	4.59E+03	2.63E+03	3.21E+03	3.53E+03
	标准差	4.05E+02	4.11E+02	6.21E+02	1.31E+02	2.71E+01
	排名	1	5	2	3	4
F22	平均值	7.23E+03	5.94E+03	6.16E+03	2.42E+03	5.89E+03
	标准差	1.47E+03	2.17E+03	2.34E+03	5.61E+02	1.86E+03
	排名	5	3	4	1	2
F23	平均值	3.56E+03	3.41E+03	3.14E+03	4.93E+03	2.86E+03
	标准差	6.42E+02	1.22E+03	5.65E+02	2.97E+03	9.17E+01
	排名	4	3	2	5	1
F24	平均值	2.83E+03	3.57E+03	3.26E+03	2.74E+03	3.10E+03
	标准差	7.26E+01	1.72E+03	1.02E+02	6.83E+02	7.01E+02
	排名	2	5	4	1	3
F25	平均值	2.67E+03	4.97E+03	3.25E+03	2.91E+03	2.83E+03
	标准差	2.30E+02	5.28E+02	8.33E+02	1.21E+02	9.48E+01
	排名	1	5	4	3	2
F26	平均值	6.43E+03	3.64E+03	9.03E+03	4.31E+03	7.01E+03
	标准差	1.46E+03	2.01E+03	7.36E+03	2.29E+02	9.04E+02
	排名	3	1	2	2	4
F27	平均值	3.08E+03	3.47E+03	3.46E+03	3.21E+03	3.26E+03
	标准差	6.72E+02	8.91E+02	7.22E+03	7.02E+02	2.08E+01
	排名	1	5	4	2	3
F28	平均值	3.36E+03	8.57E+03	3.87E+03	3.23E+03	3.24E+03
	标准差	6.11E+02	2.58E+03	2.72E+03	6.33E+02	2.3E+01
	排名	3	5	4	1	2
F29	平均值	3.56E+03	3.58E+03	5.09E+03	3.49E+03	3.98E+03
	标准差	4.43E+02	3.57E+02	5.52E+02	6.12E+02	1.41E+02
	排名	2	3	5	1	4

可以从表 5 可知,相比其他四种,在大多数测试函数上 FLHHO 获得更高的寻优能力,且稳定性也高于大多数算法。可以从平均值和方差看出,在 25 个函数上,FLHHO 的测试结果是优于 HHO 和 WOA,在求解 18 个测试函数上,FLHHO 的测试结果优于 IGWO,在求解 20 个函数上,FLHHO 优于

SSA。按总的排名来说,FLHHO 排第一,IGWO 次之,WOA 最后。并且对于求解单峰函数 F1~F3,相对其他算法 FLHHO 表现出更高的寻优精度,在多峰函数 F4~F10 上,除了在 F4 上的寻优精度略低于 IGWO 和 SSA,其他函数上都表现最优,这表明 FLHHO 能更好地平衡勘察和开发,避免陷入局部陷阱。

对于混合函数, FLHHO 在 F12、F13、F18、F20 和 F21 获得更高的求解精度, 对于其他函数表现一般。对于组合函数, FLHHO 仅在 F25 和 F27 上表现最优, 这说明在组合函数上, FLHHO 还有提升空间。

4 FLHHO 算法在工业物联网中的应用

工业物联网 (IIOT) 是指将采集到的数据通过网络传输或处理, 并不断将其应用到工业生产的各个环节, 实现工业智能化^[24]。相对传统物联网, 工业物联网 (IIOT) 需要连接更多的传感器设备, 还需要处理海量数据, 通信业务量的增加易造成了各种能量的大量消耗, 因此, 未来的网络必须满足工业物联网的各种需求, 例如频谱、功率和成本^[25], 频谱稀缺会影响到工业物联网的服务质量 (QoS)。因此, 基于认知无线电的工业物联网传感器网络可以很好地解决工业物联网中频谱利用率低的问题, 大大降低能耗。

本文结合认知工业物联网 (CIOT) 的概念, 针对大多数算法过于早熟, 不易处理高维问题, 导致频谱分配的能量效率不高的问题, 将 FLHHO 算法应用到工业物联网传感器网络的频谱分配中去, 为认知工业物联网传感器网络用户寻找最佳频谱分配方案。

在工厂场景中随机分布着主用户 (PU) 和次用户 (SU), IIOT 中的传感器节点可以被作为是 IIOT 传感器网络中的用户, 并且存在主基站 (PBS) 和认知基站 (CBS), 它们都有各自的覆盖范围, 通过在 IIOT 传感器网络中融合认知无线电技术, 使主次 IIOT 传感器网络用户实现频谱资源共享, 大幅度提升频谱资源利用率。采用集合 $\boldsymbol{p} = \{1, 2, \dots, N\}$ 表示认知用户, 集合 $\boldsymbol{R} = \{1, 2, \dots, M\}$ 表示主用户。将频谱分配^[26]映射到种群中每只哈里斯鹰的位置, 算法迭代结果中的最优种群解对应于频谱分配的能量效率, 其中, 能量效率的数学表达式为:

$$E = \sum_{m=1}^M r_n / \sum_{n=1}^N p^n \quad (27)$$

$$r_n = \sum_{m=1}^M h_{n,m} e_{n,m} \quad (28)$$

$$e_{n,m} = w \log_2(1 + \text{SINR}) \quad (29)$$

$$\text{SINR}_n = \frac{p_n s}{p_{\text{noise}}} \quad (30)$$

$$s = A \frac{1}{PL(d^n)} \quad (31)$$

式中: r_n 为次用户的效益值, p^n 是传输功率, $h_{n,m}$ 用来表示当 $h_{n,m} = 1$ 表示信道 m 可以认知用户 n 占用, $e_{n,m}$ 表示 IIOT 传感器网络用户 n 占用频谱 m 所得到的效益, w 表示带宽, SINR 表示信噪比, p_{noise} 表

示噪声功率, s 表示信道增益, A 服从瑞利分布, $PL(\cdot)$ 表示路径损耗, N 表示认知用户数, M 表示可用信道数。

考虑到现实中的功率传输和用户在通信过程中会产生路径损耗等问题, 根据文献[27], 定义用户的路径损耗模型如式 (32) 所示:

$$PL(d^n) = \begin{cases} 20 \log \left(\frac{4\pi\nu}{d^n} \right) & d^n \leq d_0 \\ 20 \log \left(\frac{4\pi\nu}{d^n} \right) + 10\mu \log \left(\frac{d^n}{d_0} \right) + \phi & d^n > d_0 \end{cases} \quad (32)$$

式中: d^n 表示 IIOT 传感器网络用户 n 到 CBS 的距离, d_0 是参考距离, ν 是发射频率波长, μ 是路径损耗因子, ϕ 是阴影参数。

因为 CBS 和 PBS 的覆盖范围交叉重叠会产生干扰, 为了有效降低干扰的影响, 本文采用基于接受信噪比的闭环功率控制算法来调整发射功率, 闭环功率控制的数学表达式如 (33) 所示:

$$P_c = \min \{ P_{\max}, P_0 + \xi PL + f(\lambda_i) \} \quad (33)$$

式中: ξ 为路径补偿参数, $P_{\max}$ 表示最大传输功率, P_0 表示用户特定的额定参数, $f(\lambda_i)$ 会根据当前用户 SINR 对发射功率进行调动, 当 $\text{SINR} < \text{SINR}_{\text{low}}$ 时, $f(\lambda_i) = 1$ 上调用户的发射功率; 当 $\text{SINR} > \text{SINR}_{\text{high}}$ 时, $f(\lambda_i) = -1$ 下调用户的发射功率; 当 $\text{SINR} \geq \text{SINR}_{\text{low}}$ 并且 $\text{SINR} \leq \text{SINR}_{\text{high}}$ 时, $f(\lambda_i) = 0$, 对用户的发射功率不做调整。

为了验证 FLHHO 算法在频谱分配上的有效性, 将 FLHHO 算法与 HHO 算法^[6]、麻雀搜索算法^[5] (SSA) 作比较。实验参数设置如表 6 所示。

表 6 仿真参数设置

参数	数值
网络区域范围	10×10
主用户数	10
认知用户数	10
可用信道数	10
最大发射功率 $P_{\max}$	24 dBm
热噪声 P_{noise}	-174 dBm
发射频率波长 ν	0.6 m
路径损耗指数 μ	3.5
影子参量 ϕ	10 dB
参考距离 d_0	1 m
系统带宽 w	1.25 MHz
路径补偿因子 ξ	0.8
信噪比上限值 $\text{SINR}_{\text{high}}$	30 dB
信噪比下限值 SINR_{low}	-20 dB

图 10 为三种不同算法的能量效率对比图,可以从图 10 看出,能量效率值会随着迭代次数的增大而增大,其中 FLHHO 的能量效率最大,HHO 次之,SSA 最差,虽然同为最近两年新提出来的群体智能算法,HHO 算法在处理工程问题上的优越性明显强于 SSA 算法。图 11 为在不同的信噪比上限值条件下的平均能量效率变化趋势图,当 SINR 上限值逐渐增大时,平均能量效率会随之增加,FLHHO 的平均能量效率增长最快,HHO 次之,SSA 的平均能量效率较两者相差过大,故在图中呈直线趋势。由此可知,SINR 上限值可以影响用户的平均能量效率,并且当参数设置越高时,平均能量效率也就越高,但 SINR 上限值设置过高会导致用户受到过大的干扰,从而减弱通信性能。




图 10 不同算法能量效率对比图




图 11 不同信干噪比下的平均能量效率

5 结论

针对 HHO 算法在优化过程中缺乏勘探和开发阶段之间的平衡的问题,本文提出一种基于混沌透镜成像学习的哈里斯鹰算法 (FLHHO),在生成种群阶段,引入 Fuch 混沌策略,丰富种群多样性,然后将黄金正弦策略用在探索阶段扩展搜索空间,提高哈里斯鹰算法的平衡能力。最后将混合透镜成像学习和柯西变异策略引入到哈里斯鹰最佳位置,来提高麻雀的收敛速度和寻优精度,在勘探和开发趋势之间建立合理的平衡。为了进一步说明所提出的 FLHHO 算法性能的优越性,将 FLHHO 与 HHO、QRHHO、MHHO、HHODE、HFPSO、IGWO、WOA 和 SSA 进行比较,并验

证三种改进策略对 FLHHO 的有效性,利用标准测试函数、Wilcoxon 秩和检验和 CEC2017 函数来验证,实验结果表明,FLHHO 的实验数据明显优于其他算法,并且在求解精度、稳定性和避免局部极值方面展示了较高的优越性。此外,将 FLHHO 算法应用到 CIOT 频谱分配优化中,以能量效率为评价指标与 HHO 和 SSA 进行对比。结果表明,FLHHO 优于其他算法,可获得更高的能量效率。


参考文献:

- [1] Mirjalili S, Lewis A. The Whale Optimization Algorithm[J]. Advances in Engineering Software, 2016, 95(5): 51-67.
- [2] Mirjalili S, Mirjalili S M, Lewis A, et al. Grey Wolf Optimizer[J]. Advances in Engineering Software, 2014, 69(3): 46-61.
- [3] Seyedali Mirjalili. Dragonfly Algorithm: A New Meta-Heuristic Optimization Technique for Solving Single-Objective, Discrete, and Multi-Objective Problems [J]. Neural Computing and Applications, 2016, 27(4): 1053-1073.
- [4] Zaldivar D, Morales B, Rodríguez A, et al. A Novel Bio-Inspired Optimization Model Based on Yellow Saddle Goatfish Behavior[J]. Biosystems, 2018, 174: 1-21.
- [5] Xue J, Shen B. A Novel Swarm Intelligence Optimization Approach: Sparrow Search Algorithm[J]. Systems ence & Control Engineering An Open Access Journal, 2020, 8(1): 22-34.
- [6] Heidari A A, Mirjalili S, Faris H, et al. Harris Hawks Optimization: Algorithm and Applications[J]. Future Generation Computer Systems, 2019, 97(8): 849-872.
- [7] Fan Q, Chen Z, Xia Z. A Novel Quasi-Reflected Harris Hawks Optimization Algorithm for Global Optimization Problems [J]. Soft Computing, 2020, 24(13): 14825-14843.
- [8] Elgamal Z M, Binti N, Tubishat M, et al. An Improved Harris Hawks Optimization Algorithm with Simulated Annealing for Feature Selection in the Medical Field[J]. IEEE Access, 2020, 8: 186638-186652.
- [9] Hussain K, Zhu W, Salleh M. Long-Term Memory Harris' Hawk Optimization for High Dimensional and Optimal Power Flow Problems[J]. IEEE Access, 2019, 7: 147596-147616.
- [10] Yildiz A R, Bureerat S, Kurtulu E, et al. A Novel Hybrid Harris Hawks-Simulated Annealing Algorithm and RBF-Based Metamodel for Design Optimization of Highway Guardrails[J]. Materials Testing, 2020, 62(3): 1-15.
- [11] Zhang X, Zhao K, Niu Y. Improved Harris Hawks Optimization Based on Adaptive Cooperative Foraging and Dispersed Foraging Strategies[J]. IEEE Access, 2020, 8: 160297-160314.
- [12] Shi X, Li M. Whale Optimization Algorithm Improved Effectiveness Analysis Based on Compound Chaos Optimization Strategy and Dynamic Optimization Parameters [C]//2019 International Conference on Virtual Reality and Intelligent Systems (ICVRIS). 2019: 123-126.
- [13] 高雷阜, 荣雪娇. 融合递减策略与 Fuch 混沌机制的改进 YSGA 算法[J]. 计算机科学与探索, 2021, 15(3): 564-576.
- [14] 毕孝儒, 牟琦, 龚尚福. 融合动态概率阈值和自适应变异的鲸

- 鱼优化算法[J]. 微电子学与计算机, 2019, 36(12): 78-83, 88.
- [15] Tanyildizi E, Demir G. Golden Sine Algorithm: A Novel Math-Inspired Algorithm[J]. Advances in Electrical and Computer Engineering, 2017, 17(2): 71-78.
- [16] Xie W, Wang J S, Tao Y. Improved Black Hole Algorithm Based on Golden Sine Operator and Levy Flight Operator[J]. IEEE Access, 2019, 7: 161459-161486.
- [17] Tizhoosh H R. Opposition-Based Learning: A New Scheme for Machine Intelligence[C]//International Conference on International Conference on Computational Intelligence for Modelling, Control & Automation. IEEE, 2005: 695-701.
- [18] 龙文, 伍铁斌, 唐明珠, 等. 基于透镜成像学习策略的灰狼优化算法[J]. 自动化学报, 2020, 46(10): 2148-2164.
- [19] Jun Li, Yangkun Luo, Chong Wang, et al. Simplified Particle Swarm Algorithm Based on Nonlinear Decrease Extreme Disturbance and Cauchy Mutation[J]. International Journal of Parallel, Emergent and Distributed Systems, 2020, 35(3): 236-245.
- [20] Awad N H, Ali M Z, Liang J J, et al. Problem Definitions and Evaluation Criteria for the CEC 2017 Special Session and Competition on Single Objective Bound Constrained Real-Parameter Numerical Optimization[R]. Zhengzhou University, Zhengzhou China and Technical Report, Nanyang Technological University, Singapore, 2016.
- [21] Zhang Y, Zhou X, Shih P C. Modified Harris Hawks Optimization Algorithm for Global Optimization Problems[J]. Arabian Journal for Science and Engineering, 2020, 45: 10949-10947.
- [22] Birogul S. Hybrid Harris Hawk Optimization Based on Differential Evolution(HHODE) Algorithm for Optimal Power Flow Problem[J]. IEEE Access, 2019, 7: 184468-184488.
- [23] Nsa B, Sta B, Sm C. An Improved Grey Wolf Optimizer for Solving Engineering Problems[J]. Expert Systems with Applications, 2020, 166: 113917-113942.
- [24] 杨伟, 汪浩, 万亚东, 曹远龙, 等. IETF 6TiSCH 工业物联网研究综述: 标准、关键技术与平台[J]. 计算机科学与探索, 2020, 14(3): 361-376.
- [25] Etim I E, Lota J. Power Control in Cognitive Radios, Internet-of-Things(IoT) for Factories and Industrial Automation[C]//IECON 2016 — 42nd Annual Conference of the IEEE Industrial Electronics Society. IEEE, 2016: 4701-4705.
- [26] Chen Y, Xiong Y, Wang Q, et al. Ensuring Minimum Spectrum Requirement in Matching-Based Spectrum Allocation[J]. IEEE Transactions on Mobile Computing, 2018, 17(9): 2028-2040.
- [27] 张达敏, 王依柔, 徐航, 宋婷婷, 王栎桥. 认知智能电网中基于能效优化的频谱分配策略[J]. 控制与决策, 2021, 36(8): 1901-1910.




尹德鑫(1996—), 女, 贵州省榕江人, 硕士研究生, 研究方向为认知无线电、优化计算, 779620087@qq.com;



张琳娜(1977—), 女, 贵州贵阳人, 副教授, 硕士, 研究方向为机械故障诊断、计算机视觉、工业产品表面缺陷检测, zln770808@163.com;



张达敏(1967—), 男, 贵州省贵阳人, 博士, 教授, 通信作者, 研究方向为认知无线电、优化计算, 1203813362@qq.com;



蔡朋宸(1996—), 男, 贵州省贵阳人, 硕士研究生, 主要研究方向为认知无线电, 1056946674@qq.com;



秦维娜(1996—), 女, 贵州省六盘水人, 硕士研究生, 研究方向为认知无线电, 1521622098@qq.com。