

控制与决策

Control and Decision

群集正反向回溯人工生态系统优化算法的ELM超参优选

赵世杰, 马世林, 王梦晨, 张红易

引用本文:

赵世杰, 马世林, 王梦晨, 张红易. 群集正反向回溯人工生态系统优化算法的ELM超参优选[J]. *控制与决策*, 2023, 38(4): 921–928.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.1624>

您可能感兴趣的其他文章

Articles you may be interested in

[阶段化改进的海洋捕食者算法及其应用](#)

Phased-improvement marine predators algorithm and its application

控制与决策. 2023, 38(4): 902–910 <https://doi.org/10.13195/j.kzyjc.2021.1749>

[多策略融合的改进麻雀搜索算法及其应用](#)

Improved sparrow search algorithm with multi-strategy integration and its application

控制与决策. 2022, 37(1): 87–96 <https://doi.org/10.13195/j.kzyjc.2021.0582>

[融合能量周期性递减与牛顿局部增强的改进HHO算法](#)

Improved harris hawks optimization coupling energy cycle decline mechanism and Newton local enhancement strategy

控制与决策. 2021, 36(3): 629–636 <https://doi.org/10.13195/j.kzyjc.2019.0810>

[基于FWADE-ELM的短时交通流预测方法](#)

Short-term traffic flow forecasting based on hybrid FWADE-ELM

控制与决策. 2021, 36(4): 925–932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

[基于FWADE-ELM的短时交通流预测方法](#)

Short-term traffic flow forecasting based on hybrid FWADE-ELM

控制与决策. 2021, 36(4): 925–932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

群集正反向回溯人工生态系统优化算法的 ELM 超参优选

赵世杰^{1,2†}, 马世林¹, 王梦晨¹, 张红易¹

(1. 辽宁工程技术大学 智能科学与优化研究所, 辽宁 阜新 123000;
2. 辽宁工程技术大学 运筹与优化研究院, 辽宁 阜新 123000)

摘要: 为有效改善极限学习机 (ELM) 的分类识别性能, 提出一种融合群集正反向回溯的改进人工生态系统优化算法 (IAEO), 并用于 ELM 的超参优选. 群集正反向引导机制启发于生态系统中消费者数量因上下级捕食关系的正反向调控机理而被构建, 局部回溯开采策略则通过继承种群历史最优信息以动态再挖掘分解者的局部微小邻域, 并引导种群进化以实现局部优化性能的改善. 数值实验结果表明, 两种改进策略可有效改善 AEO 算法的全局勘探和局部开采性能, IAEO 算法具有较高的收敛精度、强稳健性和良好的高维优化适用性; 同时验证了所提 IAEO 算法在 ELM 超参优化以增强分类泛化性能的有效性和可行性.

关键词: 智能优化算法; 人工生态系统优化算法; 群集正反向引导; 局部回溯开采; 极限学习机

中图分类号: TP183; O29 文献标志码: A

DOI: 10.13195/j.kzyjc.2021.1624

引用格式: 赵世杰, 马世林, 王梦晨, 等. 群集正反向回溯人工生态系统优化算法的 ELM 超参优选 [J]. 控制与决策, 2023, 38(4): 921-928.

Super parameter optimization of ELM by artificial ecosystem-based optimization with crowding forward-backward and backtracking tips

ZHAO Shi-jie^{1,2†}, MA Shi-lin¹, WANG Meng-chen¹, ZHANG Hong-yi¹

(1. Institute of Intelligence Science and Optimization, Liaoning Technical University, Fuxin 123000, China; 2. Institute for Optimization and Decision Analytics, Liaoning Technical University, Fuxin 123000, China)

Abstract: To effectively enhance the classification recognition performance of the extreme learning machine (ELM), an improved artificial ecosystem optimization algorithm (IAEO) with crowding forward-backward and backtracking tactics is proposed, and is employed to optimize the super parameter of the ELM. The crowding forward-backward guidance mechanism is inspired by changes of the number of consumers in an ecosystem, and is constructed by modeling the forward-backward regulating mechanism of the predator-prey relationships between the superior and subordinate organisms. And the local backtracking exploitation strategy inherits the population history optimal information to dynamically re-exploit the local micro neighborhood of decomposers, which contributes to guiding the population evolution and improving the local optimization ability. Numerical results show that two kinds of improved strategies can effectively improve the global exploration and local exploitation performance of the AEO. And the proposed IAEO has higher convergence accuracy, stronger robustness, better high-dimensional optimization applicability. The effectiveness and feasibility of the proposed IAEO algorithm in improving classification performance of the ELM by optimizing its super parameter are showed.

Keywords: intelligence optimization algorithm; artificial ecosystem-based optimization; crowding forward-backward guidance; local backtracking exploitation; extreme learning machine

0 引言

极限学习机 (extreme learning machine, ELM) 是 Huang 等^[1]提出的一种基于单隐层前馈神经网络的机器学习算法, 具有学习效率高、泛化能力强等优点, 已成功应用于图像处理、故障诊断等领域. 但 ELM 因

输入权重、隐层阈值等参数的随机性^[2]而弱化了其对数据的预测分析性能, 因此选择合适的参数对调控 ELM 的运算复杂度、分类精度等具有重要意义.

人工生态系统优化算法^[3] (artificial ecosystem-based optimization, AEO) 是一种群启发式智能优化

收稿日期: 2021-09-17; 录用日期: 2022-01-11.

基金项目: 中国博士后基金面上项目 (2021M701537); 辽宁省教育厅基金项目 (LJ2019JL017); 辽宁省科技厅博士科研启动基金项目 (2019-BS-118).

责任编辑: 巩敦卫.

†通讯作者. E-mail: zhaoshijie@lntu.edu.cn.

算法,通过模型化生态系统中生物体间能量流动的特性行为而被提出.与传统群智能算法相比,AEO算法可有效调控算法的全局探索和局部开采性能,在提升寻优效率的同时可保持均匀的种群多样性.近年来,许多学者已将AEO算法应用于实际问题以验证其工程适用性.如Essa等^[4]提出了基于AEO的新型随机矢量功能链接网络,以预测海水温室系统功耗和产水量.Yousri等^[5]提出了基于AEO的光电参数模型以识别等效电路中的未知参数,并提出基于AEO的光电阵列重构方法^[6]以设计一种提高光伏发电量的新型适应度函数.Nguyen^[7]提出了基于AEO的网络重构方法,以降低配电网功率损耗.

本文为有效提高ELM的分类识别性能,提出一种融合群集正反向回溯的改进人工生态系统优化算法(improved AEO, IAEO),并用于ELM的输入权重和隐层阈值的超参优选.群集正反向引导机制启发于自然生态系统中消费者数量因上下级捕食关系所导致的正反向动态变化规律而被构建,以期增强算法的全局探索性能;局部回溯开采策略则利用历史最优解序列与当前最优解间的微小邻域再生一个新最优解并按最优原则动态更新,以强化算法的局部开采性能.数值结果表明,IAEO可有效平衡算法的全局探索和局部勘探性能,改善AEO的收敛精度和寻优效率,实现ELM超参优选并提高其分类精度.

1 人工生态系统优化算法(AEO)

AEO算法是Zhao等^[3]基于生态系统中能量流动及生产者、消费者和分解者行为启发而提出的一种新的智能优化算法,主要包括生产阶段、消费阶段和分解阶段,生物体代表问题的可行解,分解者代表问题最优解并随迭代越趋逼近于理论最优解.

1) 生产阶段.生产者 x_1 (最劣个体)通过分解者 x_n (最佳个体)和随机个体 x_{rand} 的线性耦合迭代更新,以指导食草、杂食动物的进化,其表达式为

$$x_1(t+1) = (1-\alpha)x_n(t) + \alpha x_{\text{rand}}(t). \quad (1)$$

其中: n 为种群规模, $\alpha = (1-t/T)r_1$ 为加权系数, t 和 T 分别为当前和最大的迭代次数, $r_1 \in [0,1]$ 为一随机数; $x_{\text{rand}} = \vec{r}(U-L) + L$ 为解空间 $[L,U]$ 内的随机个体且 $\vec{r} \in [0,1]$ 为一个 D 维随机向量.

2) 消费阶段.消费者根据其食性特点可划分为食草动物、杂食动物和肉食动物,在模型中其依概率被随机赋予角色类别并按如下3种模式迭代更新.

情况1:食草动物 x_i 只能捕食生产者 x_1 ,对应的行为模型可数学化表示为

$$x_i(t+1) = x_i(t) + C \cdot (x_i(t) - x_1(t)). \quad (2)$$

其中: $i \in [2,n]$, $C = v_1/2|v_2|$ 为基于Levy飞行改进的消费因子,且 v_1 和 v_2 均服从标准正态分布.

情况2:肉食动物 x_i 只能随机捕食一个能量水平较高的消费者 x_j ,对应的行为模型可表示为

$$x_i(t+1) = x_i(t) + C \cdot (x_i(t) - x_j(t)). \quad (3)$$

其中: $i \in [3,n]$, $j = \text{randi}([2,i-1])$.

情况3:杂食动物 x_i 可捕食生产者 x_1 和一个能量水平较高的随机消费者 x_j ,对应的行为模型为

$$x_i(t+1) = x_i(t) + C \cdot (r_2 \cdot (x_i(t) - x_1(t)) + (1-r_2)(x_i(t) - x_j(t))), \\ i \in [3,n]. \quad (4)$$

其中: $j = \text{randi}([2,i-1])$, $r_2 \in [0,1]$ 为一随机数.

3) 分解阶段.生态系统中每个生物体 x_i 都会消亡并被分解者 x_n 分解,对应的分解行为模型为

$$x_i(t+1) = x_n(t) + B \cdot (e \cdot x_n(t) - h \cdot x_i(t)). \quad (5)$$

其中: $i \in [1,n]$, $B = 3u$ 为分解因子且 u 服从标准正态分布, $e = r_3 \cdot \text{randi}([1,2]) - 1$ 和 $h = 2r_3 - 1$ 均为加权系数且 $r_3 \in [0,1]$ 为一随机数.

AEO算法以随机初始化种群为起始,在迭代过程中每个生物体按其特定行为模型更新位置,以最优原则动态更新最优解,直至达到终止条件而结束.

2 群集正反向回溯人工生态系统算法

2.1 群集正反向引导机制(CFBG)

由AEO算法理论可知,种群生产者和分解者仅有一个生物体,其他均为消费者,故消费者代表的可行解在优化问题中起主导作用,其解的优劣程度决定着问题的寻优效果.因此,如何改善消费者(即问题解)的优异性将有利于AEO优化性能的提高.

在无人干预的自然生态系统中,当被捕食者数量增多时,捕食者因捕食资源充足而正向促使其种群数量增加,并反向作用导致被捕食者数量减少;继而,捕食者又因捕食资源减少而加剧种内斗争并造成种群数量的减少,以此往复,直至该生态系统捕食-被捕食者数量达到动态平衡.按该生物规律,生态系统中消费者(食草、杂食和肉食动物)的数量受其他生物体数量的影响并呈现出动态变化趋势.

AEO算法依概率均匀分配消费者数量,并未考虑生态系统中消费者数量会因上下级捕食关系而发生正反向动态调控规律.因此,为模拟该生物启发规律,构造并提出群集正反向引导机制(crowding forward-backward guidance, CFBG):消费者 x_i 通过生

物体种群中心位置 \bar{x} 与其原位置的综合作用以生成新位置 x'_i , 其对应的数学模型为

$$x'_i(t+1) = x_i(t) + k \cdot (\bar{x}(t) - x_i(t)). \quad (6)$$

其中: $\lambda \in [0, 1]$ 为一随机数; $k = 2\lambda - 1 \in [-1, 1]$ 以模拟自然生态系统的正反向调控作用; x_i 为食草动物 (herbivore) 时 $i \in [2, n]$, 为杂食 (omnivore) 和肉食动物 (carnivore) 时 $i \in [3, n]$. 故基于3种消费者的CFBG机制分别记为H-CFBG、O-CFBG和C-CFBG.

由图1可知, CFBG机制下杂食动物 x_4 以种群中心位置 \bar{x} 和正反向调控因子 k 产生新的潜在位置: 若 $k > 0$ 则 x_4 沿正向产生新位置 x_4^+ , 反之则沿反向产生 x_4^- , 以此改善AEO算法的全局探索性能.




图1 群集正反向引导机制示意(以杂食动物 x_4 为例)

2.2 局部回溯开采策略(LBES)

AEO算法将分解者作为当前动态最优解, 并以其解信息指导生物体进化而表现出重要的种群引导作用. 为进一步增强AEO算法的局部开采性能, 需对分解者的微小邻域进行再挖掘, 以期寻得更优解.

鉴于种群历史最优解序列中蕴含着重要的潜在解信息, 分解者通过继承学习这些动态解信息生成新的分解者以实现局部邻域的再开采, 并按适应度值最优原则进行位置更新. 该策略具有回溯算法“能进则进”的特点, 故称为局部回溯开采策略(local backtracking exploitation strategy, LBES).

当历史最优解序列 $\text{his } x^*$ 长度 N 超过局部回溯步长 m 时, LBES策略将被触发并倒序选取 $\text{his } x^*$ 中 m 个最优解, 计算其均值 Z 并作用于当前分解者 x^* , 以产生一个新分解者 x_{new}^* , 对应计算表达式为

$$\begin{cases} x_{\text{new}}^* = x^* + \xi \cdot (Z - x^*), \\ Z = \overline{\text{his } x^*}(N - m + 1 : N), \end{cases} \quad (7)$$

其中调控因子 $\xi \in [0, 1]$ 为一随机数. 新生 x_{new}^* 需按适应度值最优原则动态更新 x^* , 对应更新表达式为

$$x^* = \begin{cases} x_{\text{new}}^*, & f(x_{\text{new}}^*) \text{ is better than } f(x^*); \\ x^*, & \text{otherwise.} \end{cases} \quad (8)$$

注意到, x_{new}^* 优于 x^* 时也将存入 $\text{his } x^*$. LBES策略因 m 取值不同而导致其计算复杂度不同, m 越大, 计算复杂度越高, 故将该策略记作 m -LBES. 局部回溯开采策略如图2所示.




图2 局部回溯开采策略示意(以 $m = 3$ 为例)

由图2分析可知, LBES策略通过继承当前最优解 x^* 并逆序学习历史最优解序列 $\text{his } x^*$ 中3个最优解的均值 Z 信息, 以勘探并挖掘新的局部潜在位置 x_{new}^* , 以期改善AEO算法的局部开采性能.

2.3 IAEO算法的执行流程

融合第2.1节CFBG机制和第2.2节LBES策略提出改进的人工生态系统优化算法IAEO. 以O-CFBG机制为例, IAEO算法的执行伪码如下.

算法1 IAEO算法.

输入: 最大迭代次数 T 、种群规模 n 、局部回溯步长 m ;

输出: 最优解 x^* (分解者)、最优适应度值 $f(x^*)$.

- 1) 随机初始化种群 x 并计算其适应度值 $f(x)$
- 2) while $t \leq T$
- 3) 按式(1)更新生产者的位置
- 4) 按式(2)更新第1个食草动物的位置
- 5) if $r < 1/3$ //食草动物
- 6) 按式(2)更新食草动物的位置
- 7) else if $1/3 \leq r \leq 2/3$ //肉食动物
- 8) 按式(3)更新肉食动物的位置
- 9) else //杂食动物
- 10) 按式(4)更新杂食动物的位置
- 11) 按式(6)执行CFBG并同步更新杂食动物
- 12) end if
- 13) end if
- 14) 按式(5)更新种群中每个生物体的位置
- 15) if 已保存的最优解个数 $N > m$
- 16) 按式(7)和(8)执行LBES更新 x^* 及 $f(x^*)$
- 17) end if
- 18) $t = t + 1$
- 19) endwhile
- 20) return x^* 与 $f(x^*)$

3 基于IAEO的极限学习机超参优选模型

极限学习机(ELM)的分类识别性能受其输入权重 w 、隐层阈值 b 等模型参数的影响较大,本文将IAEO算法拓展用于ELM的超参优选问题,提出一种IAEO-ELM模型,以提高ELM的分类精度.

IAEO-ELM以分类准确率最大化为优化原则,其超参优选问题对应的组合优化模型可表示为

$$\begin{aligned} \max F(w, b); \\ \text{s.t. } w \in [w_{\min}, w_{\max}], b \in [b_{\min}, b_{\max}]. \end{aligned} \quad (9)$$

其中: w_{\max} 和 w_{\min} 为 w 取值的上、下界, b_{\max} 和 b_{\min} 为 b 取值的上、下界, $F(\cdot)$ 为目标函数. w 和 b 的对应维度分别为 $R \times Q$ 和 Q , 其中 R 为数据集属性数目, Q 为ELM神经元数目, 故IAEO-ELM模型待估超参数的维度可表示为 $\text{Dim} = R \times Q + Q$.

具体地, IAEO-ELM模型的执行步骤如下.

step 1: 归一化并划分数据集. 为消除数据集属性间的量纲差异, 以Z-score标准化方法对各属性数据进行归一化处理; 为实现ELM的模型训练和性能测试, 以“均匀随机选取”法^[8]将样本量为 M 的数据集随机划分为训练集 DS_{Train} 和测试集 DS_{Test} .

step 2: 模型参数设置. 预设参数有IAEO的种群规模 n 、最大迭代次数 T 、局部回溯步长 m 和ELM的神经元数目 Q 、输入权重 w 及隐层阈值 b 的上下界.

step 3: IAEO种群初始化. 按step2中参数设置随机初始化 n 个生物体, 各生物体表示ELM超参组合 (w, b) , 其中前 $R \times Q$ 个为 w 值, 后 Q 个为 b 值.

step 4: 计算种群适应度值. 以各生物体超参组合 (w, b) 构成ELM输入权重矩阵和隐层阈值向量, 并以 DS_{Train} 和 DS_{Test} 分别训练和测试ELM模型, 所得 DS_{Test} 分类准确率为对应生物体的适应度值.

step 5: 确定种群最优个体和最优适应度值. 按适应度值最大化原则确定当前种群的最优个体, 其最优适应度值表示对应ELM的最大分类准确率.

step 6: 生物体种群的迭代更新. 按IAEO机理执行生产、消费和分解阶段以迭代产生新生物体种群.

step 7: 模型终止条件的判定. 判断当前迭代次数 t 是否达到预设 T : 若是则输出种群最优个体及其最优适应度值, 即IAEO-ELM最优超参组合 (w, b) 和最大分类准确率; 否则令 $t = t + 1$, 转至step 4.

综上, IAEO-ELM模型的计算复杂度如下:

- 1) 时间复杂度.
 - ① 数据集归一化和划分的时间复杂度为 $\Theta(M)$;
 - ② 种群初始化的时间复杂度为 $\Theta(n \times \text{Dim})$;
 - ③ 生物体种群的迭代更新、适应度值计算及其

最优性判定的时间复杂度为 $\Theta(n \times \text{Dim} \times T \times M)$.

综上所述, 在忽略低阶项的前提下, IAEO-ELM模型的总时间复杂度为 $\Theta(n \times \text{Dim} \times T \times M)$.

2) 空间复杂度.

① 数据集归一化和划分的最大空间复杂度为 $\Theta(M \times (R + 1))$;

② 种群初始化的最大空间复杂度为 $\Theta(n \times \text{Dim})$;

③ LBES策略中历史最优解序列的最大空间复杂度为 $\Theta(N \times \text{Dim})$.

综上可知, IAEO-ELM模型的空间复杂度为 $\max\{\Theta(M \times (R + 1)), \Theta(n \times \text{Dim}), \Theta(N \times \text{Dim})\}$.

4 数值实验

为验证IAEO-ELM模型的良好分类识别性能, 共进行4组实验: 实验1和实验2分别探究CFBG机制和LBES策略对AEO算法的性能改善有效性; 实验3以新近智能优化算法对比性验证IAEO算法的优异寻优性能; 实验4以UCI数据集验证IAEO算法优化ELM超参模型的性能改善有效性.

4.1 CFBG机制的性能有效性分析实验

为验证CFBG机制对AEO算法的性能改善有效性, 选取基准测试函数^[9]中的4组, f_1 和 f_2 分别为单峰函数 Sum of different power 和 High Conditioned Elliptic 以测试算法的局部开采性能, f_3 和 f_4 分别为多峰函数 Salomon 和 Alpine 以测试算法的全局探索性能. 实验种群规模 n 、最大迭代次数 T 和函数维度 D 均设定为30、500和30. 为保证算法性能评价的客观性, 各实验组均独立测试30次, 以30次测试的均值(mean)、标准差(std)、最劣值(worst)和最优值(best)为评价指标, 对比结果见表1.

表1 不同CFBG机制的对比统计结果(30D)

	index	AEO	H-CFBG	O-CFBG	C-CFBG
f_1	mean	1.11e-263	5.52e-275	3.95e-274	2.26e-262
	std	0.00e+00	0.00e+00	0.00e+00	0.00e+00
	worst	3.27e-262	1.65e-273	1.18e-272	6.77e-261
	best	9.46e-290	2.08e-299	1.76e-301	1.95e-288
f_2	mean	9.80e-154	3.43e-162	3.06e-163	3.38e-157
	std	5.34e-153	1.76e-161	0.00e+00	1.80e-156
	worst	2.92e-152	9.70e-161	6.36e-162	9.85e-156
	best	4.06e-173	1.01e-183	8.17e-185	1.22e-175
f_3	mean	1.08e-73	2.22e-77	8.69e-79	9.51e-75
	std	5.84e-73	1.03e-76	4.50e-78	5.19e-74
	worst	3.20e-72	5.66e-76	2.47e-77	2.84e-73
	Best	1.39e-87	6.97e-90	9.35e-90	5.36e-87
f_4	mean	2.23e-82	5.13e-85	1.03e-86	1.69e-81
	std	8.49e-82	2.77e-84	4.06e-86	8.99e-81
	worst	4.46e-81	1.52e-83	2.18e-85	4.93e-80
	best	4.82e-93	2.61e-95	1.66e-95	1.08e-92

由表1可见,作用于不同消费者的CFBG机制对AEO的性能改善有所差异,其中O-CFBG改善效果最佳,H-CFBG次之,而C-CFBG相较于AEO算法则略有波动.究其原因,CFBG机制因作用于不同能量级别的消费者而导致其性能差异:肉食动物位于食物链顶端,对应能量水平高,因趋近于问题最优解而限制了CFBG的改善效果;食草、杂食动物位于食物链低中端,能量水平较低,故CFBG机制的正反向探索效果明显进而有效提高了算法收敛精度.

H-CFBG和O-CFBG的寻优精度无明显差异且均优于AEO算法,故惯性地二者相结合提出融合策略(记为HO-CFBG)并探究其寻优性能.在同等实验设置条件下,30次独立测试的统计结果见表2.

表2 HO-CFBG算法的测试统计结果(30D)

	mean	std	worst	best
f_1	2.65e-288	0.00e+00	6.30e-287	1.80e-312
f_2	2.05e-174	0.00e+00	6.08e-173	6.11e-198
f_3	4.51e-82	1.41e-81	6.84e-81	2.21e-94
f_4	3.49e-92	1.04e-91	4.48e-91	4.10e-101

纵向对比表1和表2的结果可知,HO-CFBG的性能指标均显著优于其他算法,特别是在H-CFBG和O-CFBG的高精度基础上仍有所提升.综上,所提出CFBG机制可有效改善AEO算法的迭代寻优性能.后续将以HO-CFBG为CFBG代表并展开实验.

4.2 LBES策略的性能有效性分析实验

为验证LBES策略对AEO性能改善的有效性,将局部回溯步长 m 分别设为10、5和3,其他参数设置同4.1节,30次测试的对比统计结果见表3.

由表3可知,3-LBES算法显著优于其他3种对比

表3 不同LBES策略的对比统计结果(30D)

	index	AEO	10-LBES	5-LBES	3-LBES
f_1	mean	1.11e-263	1.86e-262	3.71e-276	3.48e-283
	std	0.00e+00	0.00e+00	0.00e+00	0.00e+00
	worst	3.27e-262	5.16e-261	7.08e-275	6.05e-282
	best	9.46e-290	5.19e-292	2.91e-303	1.61e-307
f_2	mean	9.80e-154	3.41e-156	2.52e-164	1.09e-167
	wtd	5.34e-153	1.32e-155	0.00e+00	0.00e+00
	worst	2.92e-152	6.67e-155	7.51e-163	3.27e-166
	best	4.06e-173	1.89e-181	6.18e-185	4.63e-192
f_3	Mean	1.08e-73	1.57e-74	1.39e-78	4.52e-83
	std	5.84e-73	5.84e-74	7.39e-78	1.72e-82
	worst	3.20e-72	3.05e-73	4.05e-77	8.20e-82
	best	1.39e-87	3.45e-89	1.53e-92	1.87e-95
f_4	mean	2.23e-82	6.18e-83	1.17e-85	1.45e-89
	std	8.49e-82	2.02e-82	5.53e-85	7.36e-89
	worst	4.46e-81	8.76e-82	3.02e-84	4.04e-88
	best	4.82e-93	2.16e-92	1.53e-95	1.49e-101

算法,其相对于AEO算法提升精度达数个至数十个数量级,而5-LBES和10-LBES仅有部分小幅提升.究其原因,局部回溯步长 m 越小,相对继承新近最优信息越多,越能保证沿最优方向的持续进化并依概率勘探,寻得更优解.同时考虑到 m 越小,LBES的复杂度越低,为调控算法复杂度并保证高寻优精度,后续实验将按3-LBES展开.综上,所提出LBES策略可有效改善AEO的局部开采性能.

4.3 IAEO与新近智能优化算法的性能对比实验

为验证IAEO算法的优异寻优性能,以新近智能优化算法SBO^[10]、CSA^[11]、ASO^[12]、NNA^[13]、AEFA^[14]、EO^[15]和AEO^[3]为对比算法,模型参数设置同文献,基准测试函数的维度设置为100,其他参数设置同4.1节.30次测试的对比统计结果见表4,8种算法的平均适应度值对比曲线见图3.

表4 8种算法的对比统计结果(100D)

	index	SBO	CSA	ASO	NNA	AEFA	EO	AEO	IAEO
f_1	mean	4.83e-09*	8.43e-08*	8.33e-12*	8.88e-10*	1.93e-05*	1.47e-126*	1.39e-264*	2.08e-298
	std	1.02e-08	6.49e-08	1.50e-11	2.18e-09	4.78e-05	8.04e-126	0.00e+00	0.00e+00
	worst	3.74e-08	2.40e-07	6.46e-11	9.10e-09	2.60e-04	4.41e-125	3.54e-263	5.61e-297
	best	7.74e-16	4.11e-09	1.55e-14	5.82e-14	5.46e-08	2.68e-143	9.47e-288	1.04e-322
f_2	mean	1.25e+06*	2.03e+07*	1.96e+07*	5.12e+03*	5.92e+07*	1.57e-25*	2.49e-151*	2.46e-183
	std	4.32e+05	5.10e+06	1.00e+07	2.47e+03	2.53e+07	2.56e-25	1.36e-150	0.00e+00
	worst	2.12e+06	3.49e+07	5.24e+07	1.17e+04	1.34e+08	1.36e-24	7.45e-150	6.03e-182
	best	6.31e+05	9.96e+06	5.64e+06	1.80e+03	1.83e+07	2.58e-27	4.29e-174	2.54e-201
f_3	mean	9.01e+00*	5.37e+00	9.91e+00*	1.79e+00*	8.68e+00*	1.87e-01*	5.98e-72*	9.26e-86
	std	1.09e+00	2.92e-01	9.16e-01	4.06e-01	7.50e-01	3.46e-02	2.45e-71	2.90e-85
	worst	1.10e+01	6.00e+00	1.22e+01	2.70e+00	9.90e+00	2.00e-01	1.24e-70	1.48e-84
	best	6.86e+00	4.70e+00	7.90e+00	1.10e+00	6.92e+00	9.99e-02	2.49e-90	1.15e-96
f_4	mean	3.08e+00*	1.69e+01*	1.31e+01*	3.00e+01*	4.08e+01*	3.62e-18*	3.13e-81*	1.31e-94
	std	4.99e-01	6.76e+00	2.72e+00	6.84e+00	6.31e+00	2.69e-18	1.70e-80	5.04e-94
	worst	4.24e+00	3.56e+01	1.98e+01	4.48e+01	5.42e+01	1.20e-17	9.32e-80	2.62e-93
	best	1.93e+00	6.83e+00	6.92e+00	1.91e+01	2.74e+01	6.50e-19	5.00e-92	7.24e-106

注:*表示IAEO分别与7种新近智能优化算法的30次独立测试结果进行Wilcoxon秩和检验且 p -Value < 0.01,此符号标于mean值处.

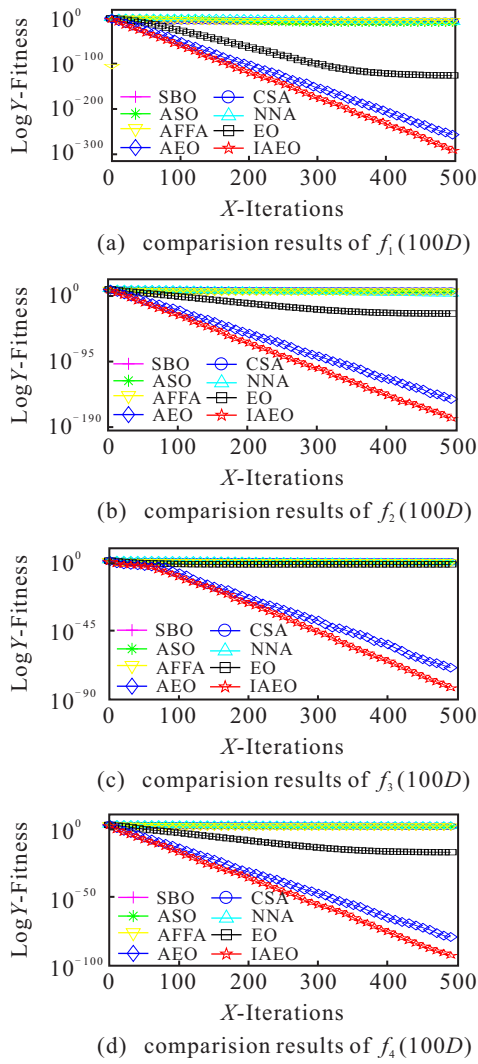


图3 8种算法的平均适应度值对比曲线

表5 4组CEC2017测试函数的对比统计结果(100D)

	index	SBO	CSA	ASO	NNA	AEFA	EO	AEO	IAEO
F_3	mean	5.68e+05	3.31e+05	6.08e+05	7.51e+05	3.79e+05	5.59e+05	2.94e+05	2.61e+05
	std	1.20e+05	2.88e+04	9.27e+04	1.40e+05	3.08e+04	1.15e+05	3.59e+04	2.46e+04
F_{11}	mean	7.67e+04	1.03e+05	1.35e+05	5.35e+04	1.99e+05	6.88e+04	1.63e+04	1.41e+04
	std	2.74e+04	1.49e+04	2.69e+04	1.33e+04	2.71e+04	1.70e+04	4.45e+03	4.16e+03
F_{13}	mean	1.77e+05	5.56e+08	9.74e+06	3.25e+06	1.78e+10	1.19e+05	5.40e+04	4.03e+04
	std	5.04e+04	2.48e+08	4.01e+07	7.12e+06	3.94e+09	4.59e+04	2.58e+04	1.27e+04
F_{16}	mean	6.66e+03	1.10e+04	7.05e+03	6.99e+03	1.38e+04	6.86e+03	6.56e+03	6.30e+03
	std	8.91e+02	1.41e+03	1.06e+03	8.75e+02	1.70e+03	9.28e+02	7.72e+02	6.05e+02

综上,IAEO算法在单/多峰、复杂函数优化中表现出更高的迭代寻优精度、更强的算法稳健性和更好的算法寻优同步性及其高维问题优化的良好适用性等.下节将测验IAEO算法在ELM超参优选中的适用性,即IAEO-ELM模型的分类识别性能.

由表4可知,IAEO算法的各项精度指标均显著优于7种对比算法:其mean值优于其他算法达十余到数百个数量级,验证了IAEO的高同步寻优精度,其更小的std值则表明IAEO具有良好的算法稳健性;此外,IAEO的worst值也几乎均优于其他算法的best值,表明在无先验知识领域,IAEO算法能够获得更好的近似最优解并表现出良好的潜在适用性,验证了所提出IAEO算法的优异寻优性能.

由图3可知,不同算法的迭代寻优进程各有不同,IAEO算法的性能表现最佳,且在同等最大迭代处寻得更优的收敛精度.6种对比算法在迭代寻优中前期便陷入局部极值而丧失掉全局寻优能力,IAEO和AEO算法始终保持良好的寻优态势且随迭代进程二者平均精度间隔呈增大趋势,直至最大迭代处达最大差距.同时,IAEO算法保有相对更大的寻优精度斜率而表现出更强的持续寻优潜力,充分验证了所提出IAEO算法具有更好的同步高精度寻优协调性、更强的全局探索和局部极值规避性等.

为进一步验证IAEO的优异寻优性能,以同等参数设置对CEC2017测试函数^[16]进行再实验,以30次独立测试的mean值和std值为算法性能评价指标.限于篇幅,仅展示部分对比统计结果(见表5).由表5可知,IAEO算法在CEC2017测试函数上仍显著优于其他7种对比算法,并保持相对更优的mean值和std值,表明所提出IAEO在复杂函数寻优中仍表现出更强的平均寻优精度和良好的算法稳健性.

4.4 IAEO-ELM模型的分类识别性能分析实验

为验证IAEO-ELM模型对改善ELM分类识别性能的有效性,选取UCI数据库中的4组分类数据集进行实验测试,按均匀随机选取法^[8]划分并得到ELM的训练集和测试集,对应数据集信息见表6.

表6 4组UCI分类数据集信息

数据集	样本数	属性数	测试数	训练数	类别数
Balance	625	4	205	420	3
Vehicle	846	18	282	564	4
Pima	768	8	253	515	2
Glass	214	9	64	150	7

为保证评价结果公平,以ELM^[1]、OS-ELM^[17]和KELM^[18]作为IAEO-ELM(IELM)的对比模型,其中ELM、OS-ELM和IELM均选用Sin激活函数,KELM选用RBF核函数. 设各ELM模型的神经元数目 Q 均为10,并设IAEO的种群规模 n 和最大迭代次数 T 分别为10和200,各实验组独立运行30次并以30次测试的分类准确率平均值(average)、标准差(std)、最大值(max)和最小值(min)作为评价指标,对比统计结果见表7.

表7 IELM和其他3种模型的对比统计结果

data set	index	ELM	OS-ELM	KELM	IELM
Balance	average	0.8341	0.8502	0.8906	0.9276
	std	0.0400	0.0450	0.0129	0.0022
	max	0.9171	0.9024	0.9171	0.9366
	min	0.7463	0.7073	0.8683	0.9268
Vehicle	average	0.4647	0.4657	0.7460	0.7765
	std	0.0438	0.0613	0.0214	0.0241
	max	0.5532	0.5780	0.8085	0.8262
	min	0.3865	0.3333	0.7092	0.7270
Pima	average	0.6839	0.6903	0.7688	0.8163
	std	0.0344	0.0335	0.0196	0.0178
	max	0.7470	0.7470	0.8063	0.8498
	min	0.6166	0.6245	0.7312	0.7708
Glass	average	0.5510	0.5589	0.5984	0.7359
	std	0.0624	0.0495	0.0509	0.0334
	max	0.6563	0.6563	0.6875	0.7969
	min	0.3750	0.4531	0.4844	0.6719

由表7可知,IELM模型分类效果几乎均优于其他对比模型,在15/16指标上性能表现最佳. IELM的最优average值表明其具有更高的平均分类精度,相对更优的std指标佐证IELM的良好分类稳健性,最好max值表明IELM表现出更强的极优分类能力,而最大min值则表明在无先验知识情况下IELM具有相对更小的分类损失. 上述结果有效验证了IAEO对ELM超参优选的优异分类性能.

为直观展示IELM的高分类精度同步性,绘制4种模型30次测试的分类精度箱线对比示意图4.

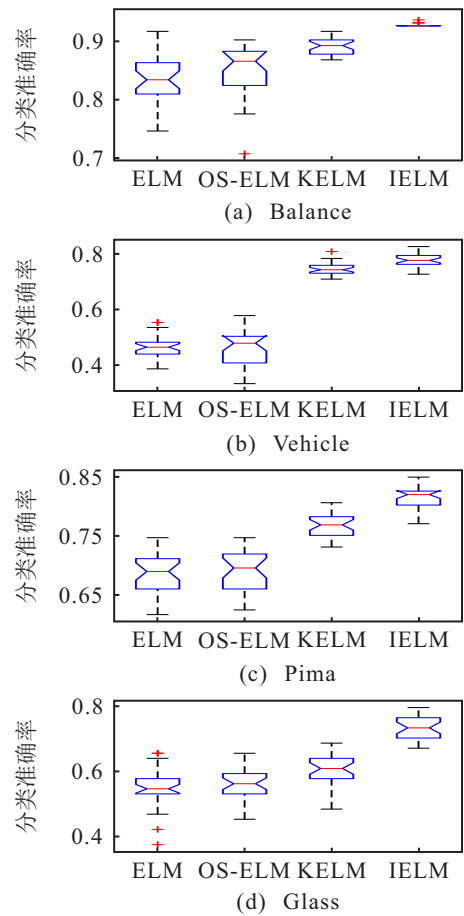


图4 4种ELM模型分类精度箱线对比示意

由图4可知,IELM模型在测试数据集上的分类性能均显著高于其他3种对比模型:测试分类精度的分布相对集中,表明IELM具有相对较强的多轮测试高精度同步特性和良好的模型鲁棒性;四分位数显著优于其他模型,特别是下四分位数仍明显优于其他模型的上四分位数,充分表明所提出模型具有更好的单次高分类精度和相对更小的潜在应用风险,进一步可视化地验证了IAEO优化ELM超参(IAEO-ELM)模型在高精度分类中的良好适用性.

综上,IAEO算法具有更为优异的迭代寻优性能和高收敛精度、良好的算法稳健性和高维问题优化适用性. 同时,IAEO-ELM模型表现出更强的高精度分类泛化性能、良好的模型鲁棒性,充分验证了IAEO优化ELM超参并提高其分类性能的有效性.

5 结论

针对极限学习机(ELM)因输入权重和隐层阈值的设定随机性而弱化了其分类识别性能等缺陷,提出了一种融合群集正反向引导机制和局部回溯开采策略的改进人工生态系统优化算法(IAEO),以组合优化方式优选ELM模型的最优超参组合并改善其分类

泛化能力. IAEO算法可有效避免潜在可行解的信息丢失、更好地平衡算法的全局探索和局部勘探能力,以提高算法的收敛精度和模型稳健性. 实验结果表明, IAEO算法具有良好的迭代寻优性能和高维函数优化适用性,并在ELM超参优选上表现出优异分类精度和强稳健性. 后续工作重点将探究IAEO算法在高维多目标优化、ELM回归问题中的适用性.

参考文献(References)

- [1] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: A new learning scheme of feedforward neural networks[C]. IEEE International Joint Conference on Neural Networks. Budapest, 2004: 985-990.
- [2] Zhu Q Y, Qin A K, Suganthan P N, et al. Evolutionary extreme learning machine[J]. Pattern Recognition, 2005, 38(10): 1759-1763.
- [3] Zhao W G, Wang L Y, Zhang Z X. Artificial ecosystem-based optimization: A novel nature-inspired meta-heuristic algorithm[J]. Neural Computing and Applications, 2020, 32(13): 9383-9425.
- [4] Essa F A, Abd Elaziz M, Elsheikh A H. Prediction of power consumption and water productivity of seawater greenhouse system using random vector functional link network integrated with artificial ecosystem-based optimization[J]. Process Safety and Environmental Protection, 2020, 144: 322-329.
- [5] Yousri D, Rezk H, Fathy A. Identifying the parameters of different configurations of photovoltaic models based on recent artificial ecosystem-based optimization approach[J]. International Journal of Energy Research, 2020, 44(14): 11302-11322.
- [6] Yousri D, Babu T S, Mirjalili S, et al. A novel objective function with artificial ecosystem-based optimization for relieving the mismatching power loss of large-scale photovoltaic array[J]. Energy Conversion and Management, 2020, 225: 113385.
- [7] Nguyen T T. A novel metaheuristic method based on artificial ecosystem-based optimization for optimization of network reconfiguration to reduce power loss[J]. Soft Computing, 2021, 25(23): 14729-14740.
- [8] 高雷卓, 赵世杰, 高晶. 人工鱼群算法在SVM参数优化选择中的应用[J]. 计算机工程与应用, 2013, 49(23): 86-90.
(Gao L F, Zhao S J, Gao J. Application of artificial fish-swarm algorithm in SVM parameter optimization selection[J]. Computer Engineering and Applications, 2013, 49(23): 86-90.)
- [9] Pan Q K, Sang H Y, Duan J H, et al. An improved fruit fly optimization algorithm for continuous function optimization problems[J]. Knowledge-Based Systems, 2014, 62: 69-83.
- [10] Samareh Moosavi S H, Khatibi Bardsiri V. Satin bowerbird optimizer: A new optimization algorithm to optimize ANFIS for software development effort estimation[J]. Engineering Applications of Artificial Intelligence, 2017, 60: 1-15.
- [11] Askarzadeh A. A novel metaheuristic method for solving constrained engineering optimization problems: Crow search algorithm[J]. Computers & Structures, 2016, 169: 1-12.
- [12] Zhao W G, Wang L Y, Zhang Z X. Atom search optimization and its application to solve a hydrogeologic parameter estimation problem[J]. Knowledge-Based Systems, 2019, 163: 283-304.
- [13] Sadollah A, Sayyaadi H, Yadav A. A dynamic metaheuristic optimization model inspired by biological nervous systems: Neural network algorithm[J]. Applied Soft Computing, 2018, 71: 747-782.
- [14] Anita Yadav A. AEFA: Artificial electric field algorithm for global optimization[J]. Swarm and Evolutionary Computation, 2019, 48: 93-108.
- [15] Faramarzi A, Heidarinejad M, Stephens B, et al. Equilibrium optimizer: A novel optimization algorithm[J]. Knowledge-Based Systems, 2020, 191: 105190.
- [16] Wu G, Mallipeddi R, Suganthan P N. Problem definitions and evaluation criteria for the CEC2017 competition on constrained real-parameter optimization[R]. Changsha: National University of Defense Technology, 2017.
- [17] Liang N Y, Huang G B, Saratchandran P, et al. A fast and accurate online sequential learning algorithm for feedforward networks[J]. IEEE Transactions on Neural Networks, 2006, 17(6): 1411-1423.
- [18] Huang G B, Zhou H M, Ding X J, et al. Extreme learning machine for regression and multiclass classification[J]. IEEE Transactions on Systems, Man, and Cybernetics, 2012, 42(2): 513-529.

作者简介

赵世杰(1987—),男,副教授,博士,从事智能优化与计算、机器学习与数据解析、水下定位与匹配导航等研究, E-mail: zhaoshijie@lntu.edu.cn;

马世林(1997—),男,硕士生,从事高维多目标优化、智能计算与数据挖掘的研究, E-mail: Msl20181210@163.com;

王梦晨(1998—),女,硕士生,从事特征选择、数据挖掘与智能优化的研究, E-mail: Wang_mengchen@163.com;

张红易(1997—),男,硕士生,从事多目标智能优化、数据挖掘与解析的研究, E-mail: zhy121657@163.com.

(责任编辑: 郑晓蕾)