

控制与决策

Control and Decision

基于反时限混沌郊狼优化算法的BP神经网络参数优化

刘威, 付杰, 周定宁, 王薪予, 成秘, 黄敏, 靳宝, 牛英杰

引用本文:

刘威, 付杰, 周定宁, 等. 基于反时限混沌郊狼优化算法的BP神经网络参数优化[J]. *控制与决策*, 2021, 36(10): 2339–2349.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.0408>

您可能感兴趣的其他文章

Articles you may be interested in

基于SAPSO算法的RBF神经网络设计

Design of RBF neural network based on SAPSO algorithm

控制与决策. 2021, 36(9): 2305–2312 <https://doi.org/10.13195/j.kzyjc.2020.0176>

基于混沌“微变异”自适应遗传算法

Adaptive genetic algorithm based on chaos “micro variation”

控制与决策. 2021, 36(8): 2042–2048 <https://doi.org/10.13195/j.kzyjc.2021.0319>

基于小波变换与差分变异BSO–BP算法的大坝变形预测

Dam deformation prediction based on wavelet transform and differential mutation BSO–BP algorithm

控制与决策. 2021, 36(7): 1611–1618 <https://doi.org/10.13195/j.kzyjc.2019.1431>

嵌入Circle映射和逐维小孔成像反向学习的鲸鱼优化算法

Whale optimization algorithm for embedded Circle mapping and one–dimensional oppositional learning based small hole imaging

控制与决策. 2021, 36(5): 1173–1180 <https://doi.org/10.13195/j.kzyjc.2019.1362>

基于自适应正态云模型的灰狼优化算法

Grey wolf optimization algorithm based on adaptive normal cloud model

控制与决策. 2021, 36(10): 2562–2568 <https://doi.org/10.13195/j.kzyjc.2020.0233>

基于反时限混沌郊狼优化算法的BP神经网络参数优化

刘威^{1,2†}, 付杰^{1,2}, 周定宁³, 王薪予^{1,2},
成秘^{1,2}, 黄敏^{1,2}, 靳宝^{1,2}, 牛英杰^{1,2}

(1. 辽宁工程技术大学理学院, 辽宁阜新 123000; 2. 辽宁工程技术大学智能工程与数学研究院, 辽宁阜新 123000; 3. 成都数联铭品科技有限公司, 成都 610000)

摘要: 针对郊狼优化算法优化性能弱及多样性低等问题, 提出一种基于反时限衰减算子的混沌郊狼优化算法 (ICCOA)。首先, 在个体迭代更新过程加入反时限衰减权重因子, 使得全局搜索与局部开发能力保持平衡的同时提高算法的搜索速度; 其次, 加入基于 Tent 混沌映射的混沌干扰机制, 将种群中部分较差个体经过映射产生新个体, 进而增大种群多样性; 接着, 为了验证 ICCOA 算法的优化能力, 分别在 10、30 和 100 维度下进行函数优化测试, 并与 5 种优化算法进行比较, 其实验结果表明 ICCOA 算法具有良好的优化性能; 最后, 将 ICCOA 算法应用于 BP 神经网络参数优化, 提出新的神经网络模型 (ICCOABP), 并与标准神经网络、基于遗传算法的 BP 神经网络参数优化方法一同应用于机器学习的分类任务进行性能比较, 实验结果表明 ICCOABP 算法具有高效性。

关键词: 郊狼优化; 反时限; Tent 混沌映射; 神经网络; 机器学习

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.0408

开放科学(资源服务)标识码(OSID):



引用格式: 刘威, 付杰, 周定宁, 等. 基于反时限混沌郊狼优化算法的 BP 神经网络参数优化 [J]. 控制与决策, 2021, 36(10): 2339-2349.

Parameter optimization of BP neural network based on coyote optimization algorithm with inverse time chaotic

LIU Wei^{1,2†}, FU Jie^{1,2}, ZHOU Ding-ning³, WANG Xin-yu^{1,2}, CHENG Mi^{1,2}, HUANG Min^{1,2}, JIN Bao^{1,2}, NIU Ying-jie^{1,2}

(1. College of Science, Liaoning Technical University, Fuxin 123000, China; 2. Institute of Intelligent Engineering and Mathematics, Liaoning Technical University, Fuxin 123000, China; 3. Business Big Data Technology Co., Ltd, Chengdu 610000, China)

Abstract: A chaotic coyote optimization algorithm based on inverse time-decay operators, named ICCOA, is proposed to solve the problems of the coyote optimization algorithm(COA), such as the poor performance and low diversity. Firstly, the inverse time decay weight factor is added in the process of individual iterative updating, so as to maintain the balance between global search and local development ability and improve the search speed of the algorithm. Secondly, the chaotic interference mechanism based on the Tent chaotic map is added, and some poor individuals in the population are mapped to produce new individuals, thus increasing the diversity of the population. In order to verify the optimization ability of the ICCOA, functional optimization tests are carried out in 10, 30 and 100 dimensions respectively, and compared with five optimization algorithms. The experimental results show that the ICCOA has good optimization performance. Finally, the ICCOA is applied to the parameter optimization of the BP neural network, and a new neural network model BP neural network with ICCOA (ICCOABP) is proposed. Compared with the standard neural network and the BP neural network parameter optimization method based on the genetic algorithm, the experimental results show the efficiency of the ICCOABP algorithm.

Keywords: coyote optimization algorithm; inverse time; Tent chaotic map; neural network; machine learnin

0 引言

随着科学技术的不断发展, BP 神经网络已广泛应用于语言、视觉等众多领域, BP 神经网络具有独特

的误差逆向传播过程, 算法可以通过不断修正权值和阈值减少训练时间并提高精度, 但目前神经网络依然存在容易陷入局部最优的问题。因此, 探索高质量的

收稿日期: 2020-04-11; 修回日期: 2020-06-03.

基金项目: 国家自然科学基金项目 (51974144, 71771111, 51874160); 辽宁工程技术大学学科创新团队项目 (LNTU20TD-01, LNTU20TD-07).

†通讯作者. E-mail: lv8218218@126.com.

BP神经网络结构成为当前人工智能研究领域待解决的关键问题之一。

郊狼优化算法是 Pierezan 等^[1]提出的一种智能仿生优化算法,与其他元启发式算法相比,COA (coyote optimization algorithm) 具有独特的算法结构,为优化过程中探索与开发的平衡^[2]提供了新的机制。COA 可以在提高收敛效率的同时保持较高的种群多样性,在众多元启发式算法中表现出较为优异的性能。但是,著名的 no free lunch 定理^[3]指出:没有任何一种普遍适用的“通用算法”能够解决所有优化问题。因此,需根据不同优化问题的特点合理地提出新算法与改进算法。

COA 提出的时间较短,张新明等^[4-5]提出的基于全局引导与相互作用以及基于信息共享模型的郊狼算法是当前仅有的相关研究,算法性能还存在着较大提升空间。为了更好地发挥 COA 在解决复杂优化问题方面的性能优势,本文提出一种反时限混沌郊狼算法——ICCOA(COA with inverse time chaotic)。ICCOA 将反时限权重和混沌机制加入郊狼种群的迭代更新过程,通过对每代郊狼个体添加动态权重因子,改变个体更新时的变化程度,使算法在迭代后期能够进行更精确的局部开发,加快收敛速度。通过以线性递减概率将较差个体作为初值代入混沌机制,并由经 Tent 映射获得的新个体所取代,较好地保持了郊狼的种群多样性。数值实验结果有效验证了 ICCOA 具有更好的局部开发能力和全局搜索能力,提高了收敛速度。在此基础上,将 ICCOA 作为优化策略,融入到 BP 神经网络结构优化过程中,设计一种全新的 BP 神经网络权值、阈值更新方法 ICCOABP(BP neural network with ICCOA),进一步的数值实验结果表明,ICCOABP 在机器学习分类任务中表现优异,充分验证了 ICCOA 作为参数优化策略的可行性和有效性。

1 郊狼优化算法

COA 模拟郊狼种群的出生、成长、死亡及迁移等生活现象,具体流程如下。

step 1: 设置郊狼群体 N_p , 每群含郊狼个体数 N_c 、维度 D 、终止条件 nfevalmax 等参数。

step 2: 随机初始化郊狼群, t 时刻下 p 群内第 i 个郊狼个体定义为

$$x_{c,j}^{p,t} = lb_j + r_j(ub_j - lb_j), \quad (1)$$

$$x_c^{p,t} = (x_{c,1}^{p,t}, x_{c,2}^{p,t}, \dots, x_{c,D}^{p,t}). \quad (2)$$

其中: ub_j 、 lb_j 分别为第 j 维数值的上、下界, r_j 为随

机生成的 $[0,1]$ 范围内的实数。

step 3: 评价郊狼适应能力

$$fit_i^{p,t} = f(x_i^{p,t}). \quad (3)$$

step 4: 郊狼有时会脱离或者被驱逐出原群体,形成群体变迁,其发生概率定义为

$$P_e = 0.005N_c^2, N_c \leq 14. \quad (4)$$

step 5: 找到当前群内的头狼 $\alpha^{p,t}$, 计算当前郊狼群体的文化趋势 $\text{clut}^{p,t}$, 有

$$\alpha^{p,t} = \{x_i^{p,t} \mid \arg_{\{i=1,2,\dots,N_c\}} \min f(x_i^{p,t})\}. \quad (5)$$

$$\text{clut}_j^{p,t} = \begin{cases} O_{\frac{N_c+1}{2},j}^{p,t}, & N_c \text{ 为奇数;} \\ O_{\frac{N_c}{2},j}^{p,t} + O_{\frac{N_c+1}{2},j}^{p,t}, & \text{otherwise.} \end{cases} \quad (6)$$

其中 $O_{\frac{N_c+1}{2},j}^{p,t}$ 表示当 N_c 为奇数时, t 时刻 p 群内所有郊狼第 j 维度变量的中位数。

step 6: 模拟遗传中的出生和死亡事件。将郊狼年龄(以年为单位)记为 $\text{age}_c^{p,t}$, 新郊狼的出生 ($\text{pup}^{p,t}$) 写成双亲(随机选择)的社会状态加上环境影响的组合, 即

$$\text{pup}_j^{p,t} = \begin{cases} x_{m_1,j}^{p,t}, & \text{rand}_j < P_s \text{ or } j = j_1; \\ x_{m_2,j}^{p,t}, & \text{rand}_j \geq P_s + P_a \text{ or } j = j_2; \\ R_j, & \text{otherwise.} \end{cases} \quad (7)$$

其中: m_1 、 m_2 为来自 p 狼群内的随机郊狼, j_1 、 j_2 为问题的两个随机维数, R_j 、 rand_j 为由均匀概率产生的 $[0,1]$ 内的随机数。离散概率 (P_s) 和关联概率 (P_a) 影响郊狼群中个体的文化多样性, 定义为

$$P_s = \frac{1}{D}, P_a = \frac{1 - P_s}{2}. \quad (8)$$

假定 ω 表示群体中的郊狼适应能力不如幼崽, ϕ 为当前群体中郊狼的数量, 若 ϕ 为 1 且 ω 成立, 即某群体中郊狼数量为 1 且幼狼的适应能力比仅有的一只郊狼高, 则幼狼存活, 群体中唯一的郊狼死亡; 若 ϕ 大于 1 且 ω 成立, 则幼狼存活, 群体中年龄最大的郊狼死亡; 其余情况幼狼死亡。

step 7: 计算头狼与群体文化趋势对当前时刻所对应的郊狼群内个体更新产生的影响 δ_1 、 δ_2 , 有

$$\delta_1 = \alpha^{p,t} - x_{cr_1}^{p,t}, \delta_2 = \text{cult}^{p,t} - x_{cr_2}^{p,t}, \quad (9)$$

其中 cr_1 、 cr_2 分别为当前群内的随机郊狼。

step 8: 对郊狼群内所有郊狼个体依次进行更新得到新的郊狼个体 $\text{new}_x^{p,t}_i$, 择优选择新郊狼与原郊狼的适应度大小, 并保留最优郊狼 $x_i^{p,t+1}$, 有

$$\text{new}_x^{p,t}_i = x_i^{p,t} + r_1\delta_1 + r_2\delta_2. \quad (10)$$

$$x_i^{p,t+1} = \begin{cases} \text{new_}x_i^{p,t}, & f(\text{new_}x_i^{p,t}) < f(x_i^{p,t}); \\ x_i^{p,t}, & \text{otherwise.} \end{cases} \quad (11)$$

其中 r_1 和 r_2 为均匀概率生成的 $[0,1]$ 范围内的实数, 代表郊狼个体受 alpha 狼与群体文化趋势影响的权重大小。

step 9: 模拟个体随时间的推移而成长的过程, 对郊狼个体进行年龄更新。

step 10: 判断终止条件, 若达到则输出适应能力最好的郊狼的社会状态, 否则返回 step 3。

2 反时限混沌郊狼优化算法

为了提高 COA 算法的收敛速度, 尽可能避免算法陷入局部最优, 并增大种群的多样性, 本文从以下两方面对 COA 作出改进: 一方面加入反时限衰减权重因子, 以保证加快算法收敛速度, 保持全局搜索与局部开发能力的平衡; 另一方面加入 Tent 混沌干扰, 将种群中部分个体经过映射产生新个体, 增大种群多样性。提出反时限混沌郊狼优化算法 ICCOA, 对这两方面的具体实现方法分别详细介绍并给出算法实现步骤。

2.1 反时限衰减权重

COA 算法因其本身独特的算法机制, 在性能上具有一定优势, 但是在求解高维复杂函数时, 相对一些智能改进算法仍具有不足, 易陷入局部最优且很难跳出局部极值; 此外, 算法一直保持恒定的更新机制, 弱化了搜索能力。为了使郊狼跳出局部极值的概率增大, 提高算法的搜索能力, 本文受机器学习中学习率衰减策略的启发, 在郊狼个体更新公式中引入反时限衰减惯性权重因子, 改进后的公式为

$$\text{new_}x_i^{p,t} = \omega \cdot x_i^{p,t} + r_1 \delta_1 + r_2 \delta_2, \quad (12)$$

其中 ω 为郊狼社会状态的惯性权重。

为了平衡算法的全局搜索能力和局部开发能力, 设置 ω 遵循以下原则: 前期 ω 值相对较大以加大算法对目标解的搜索步长, 尽可能提高算法的收敛速度; 后期将 ω 值设定较小可以避免 ω 过大造成郊狼受上一代个体影响过大进而弱化问题的最优解。传统权重策略的初始值以及迭代至最大次数时的最大权重值大多通过大量实验确定, 增加了计算的复杂性, 而反时限衰减公式^[6]不固定最小学习率, 迭代次数越多, 学习率越小, 故将 ω 设置为反时限衰减惯性权重, 定义为

$$\omega(k) = (1 + \gamma \cdot k)^{-p}, \quad \gamma = 0.99. \quad (13)$$

其中: k 为当前迭代次数; 为了防止衰减速率过大可能会造成的最优解丢失, 定义 $p = 0.25$ 。

2.2 混沌干扰

在 COA 算法中, 小狼的出生是决定种群多样性的唯一条件, 小狼个体的基因可能取决于父母一方, 也可能随机产生, 此时高随机性使得种群多样性增加, 但由于小狼“夭折率”过高^[7-8], 在后期小狼与老狼的优胜劣汰中留下的往往是老狼, 局限了算法对最优解的搜索, 种群多样性未能得以保证。本文在群体变迁操作之前引入混沌 Tent 映射, 将当前时刻适应度较差的 $1/N_c$ 个体作为初值代入 Tent 映射生成新个体并取代。同时, 考虑到算法全局与局部寻优性能的平衡, 对混沌干扰机制定义执行概率 r , 并结合传统权重递减策略将其定义为线性递减函数^[9]。根据文献^[10]指出 Tent 映射的遍历均匀性更好, 寻优效率更高, 其表达式为

$$x_{n+1} = \begin{cases} 2x_n, & x_n \in [0, 0.5]; \\ 2(1 - x_n), & x_n \in (0.5, 1]. \end{cases} \quad (14)$$

式(14)经伯努利移位变换后的数学表达式为

$$x_{n+1} = (2x_n) \bmod 1. \quad (15)$$

设定阈值 R , 计算混沌扰动执行概率 r , 有

$$r = r_{\max} - (r_{\max} - r_{\min}) \frac{k}{T_{\max}}, \quad (16)$$

其中 T_{\max} 为最大迭代次数。通过探测机制寻找到 $1/N_c$ 适应度较差的个体作为初始值代入 Tent 映射进而产生等量新个体取代原个体。

由于映射中 \bar{x}_i 的范围在 $[0,1]$ 之间, 与 COA 算法的个体 $x_i^{p,t}$ 不同, 需要进行变量转换。将 COA 算法原变量映射到 $[0,1]$, 有

$$\bar{x}_{i,j}^t = \frac{x_{i,j}^{p,t} - \text{lb}_j}{\text{ub}_j - \text{lb}_j}, \quad j = 1, 2, \dots, D. \quad (17)$$

其中: ub_j 、 lb_j 分别为 t 时刻 p 群体第 j 维变量的上、下界; $x_{i,j}^{p,t}$ 为 t 时刻个体第 j 维的变量, $\bar{x}_{i,j}^t$ 为 t 时刻个体第 j 维变量经 Tent 映射转换后对应的维度变量。

利用 Tent 映射表达式将式(17)变成混沌变量序列 ($i = 1, 2, \dots, N_c, m = 1, 2, \dots, C_{\max}$), 其中 C_{\max} 为混沌搜索最大迭代次数。

利用下式将 $\bar{x}_i(m)$ 映射至原解空间, 产生新个体 $\text{new_}x_i^{p,t}$:

$$\text{new_}x_{i,j}^{p,t} = x_{i,j}^{p,t} + \frac{\text{lb}_j - \text{ub}_j}{2} (2\bar{x}_{i,j}(m) - 1). \quad (18)$$

2.3 ICCOA 算法描述

ICCOA 算法流程如图 1 所示。

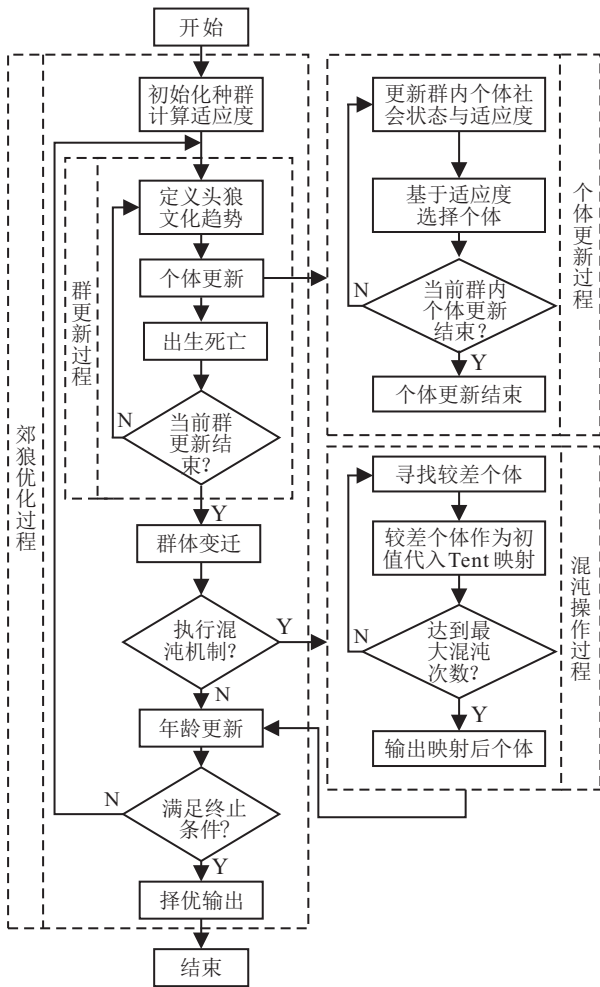


图1 ICCOA算法流程

ICCOA算法伪代码描述如下:

1. 开始
2. 设置参数 N_c 、 N_p , 初始化郊狼种群(式(1))
3. 计算郊狼的适应能力(式(3))
4. while 未满足终止条件
5. year = year + 1
6. for $p = 1 : N_p$
7. 计算头狼 alpha 及文化趋势 cult(式(5)和(6))
8. 计算头狼和群体的影响大小(式(6))
9. for $i = 1 : N_c$
10. 更新当前郊狼(式(12)和(13)), 对比更新前后的郊狼适应能力, 保留较优郊狼(式(11))
11. end i
12. 记录出生与死亡
13. end p
14. 群体变迁
15. if 满足阈值
16. 找到当前 $1/N_c$ 数量的较差郊狼执行混沌操作, 产生新郊狼
17. end if

18. 年龄更新
19. end while
20. 择优选取最优郊狼
21. 结束

3 数值实验

为了客观地测试ICCOA算法的性能优势, 引入基于Levy飞行的混合蛙跳算法(LSFLA)^[11]、混合作用力微粒群优化算法(HFPSO)^[12]、灰狼优化算法(GWO)^[13]、蝴蝶优化算法(BOA)^[14]与ICCOA、COA在一组基准函数上进行对比实验. 其中:LSFLA是混合蛙跳算法(SFLA)的变体, 在性能上优于SFLA^[15]和其他许多算法^[16]; 粒子群算法(PSO)^[17]是经典的启发式优化算法, HFPSO作为萤火虫算法(FA)^[18]与PSO的混合算法, 结合了粒子群与萤火虫算法的优点, 具有很好的性能优势; BOA为与COA同年提出的另一种优化算法, GWO与COA同为狼类优化器. 以上算法具有较强的代表性和可比性. 表1给出了15个测试函数的信息, 其中 $f_1 \sim f_9$ 为多维多峰函数, 具有多个局部最优点; $f_{10} \sim f_{15}$ 为多维单峰函数, 且 f_2 自变量互相影响, f_1 有多个局部极值和障碍物. 这些函数求解难度高, 适合用于测试算法的求解能力和寻优能力.

表1 基准函数信息

特征	序号	函数名称	变量区间
多峰	f_1	Ackley	[-32, 32]
	f_2	Griewank	[-600, 600]
	f_3	Rastrigin	[-5.12, 5.12]
	f_4	Sphere	[-5.12, 5.12]
	f_5	Apline01	[-2, 2]
	f_6	Sdop	[-1, 1]
	f_7	Cigar	[-100, 100]
	f_8	Powell	[-4, 5]
	f_9	Schwefel22	[-500, 500]
单峰	f_{10}	Schwefel01	[-100, 100]
	f_{11}	Schwefel02	[-100, 100]
	f_{12}	Schwefel20	[-100, 100]
	f_{13}	Schwefel21	[-100, 100]
	f_{14}	Rothyp	[-65, 65]
	f_{15}	SumSquare	[-5.12, 5.12]

1) 优化性能分析.

为了避免随机性对实验结果的影响, 保证实验环境的绝对公平, 在仿真实验中, 将所有算法的公共参数设置相同, 设置函数维度分别为 $D = 10, 30, 100$; 各算法种群数量为 $popsize = 100$, COA算法与

ICCOA算法的终止条件为 $nfevalmax = 10000 \times D$, 各算法的迭代次数为

$$\max = \text{ceil}((nfevalmax - \text{opsize}) / (\text{popsize} + N_c)),$$

设置 $N_c = N_p = 10$. 6种算法对每一个优化问题在3种维度下均独立进行30次实验.

本文提出的ICCOA算法以及对比算法在15个标准测试函数上的实验结果如表2所示. 由表2可见: 所提出的ICCOA算法在15个函数上的优化结果总体上优于其他5种算法. 当维数为10时, ICCOA算法在13个测试函数下的最优结果皆优于其余5种对

表2 各算法在15个测试函数上的实验结果

函数	维度	GWO	BOA	COA	HFPSO	FLSLA	ICCOA
f_1	10	4.44e-15	1.13e-12	1.79e-06	1.17e-14	2.50e+00	8.88e-16
	30	7.88e-15	8.88e-16	1.50e-06	3.57e-14	6.09e-01	8.88e-16
	100	1.51e-14	8.88e-16	2.97e-04	1.60e-12	3.27e-03	8.88e-16
f_2	10	1.17e-02	0.00e+00	1.22e-02	5.60e-02	1.15e+00	0.00e+00
	30	3.32e-04	0.00e+00	2.47e-04	9.68e-03	7.21e-01	0.00e+00
	100	0.00e+00	0.00e+00	3.20e-03	4.02e-03	5.28e-03	0.00e+00
f_3	10	0.00e+00	1.34e+01	1.47e-06	3.75e+00	7.64e+00	0.00e+00
	30	0.00e+00	0.00e+00	6.97e-02	3.48e+01	1.77e+00	0.00e+00
	100	0.00e+00	0.00e+00	9.55e-01	1.60e+02	9.77e-04	0.00e+00
f_4	10	4.20e-163	1.85e-14	2.58e-14	8.13e-31	3.87e-02	0.00e+00
	30	3.14e-242	8.69e-19	1.95e-15	1.29e-29	1.11e-02	0.00e+00
	100	0.00e+00	2.43e-25	1.75e-16	1.52e-28	2.54e-07	0.00e+00
f_5	10	5.08e-05	7.33e-14	2.99e-06	2.15e-16	8.30e-02	0.00e+00
	30	1.44e-07	4.24e-27	2.35e-05	5.78e-14	1.38e-02	0.00e+00
	100	7.22e-237	6.81e-59	9.12e-05	5.77e-04	1.99e-04	0.00e+00
f_6	10	1.03e-165	1.65e-14	1.18e-15	5.90e-31	2.38e-03	0.00e+00
	30	1.61e-243	7.99e-19	6.97e-17	6.23e-30	0.25e-03	0.00e+00
	100	0.00e+00	7.03e-24	8.90e-17	6.93e-27	2.95e-07	0.00e+00
f_7	10	8.16e-156	3.23e-14	1.64e-06	1.64e-24	1.74e+07	0.00e+00
	30	2.71e-233	1.02e-18	4.99e-07	3.33e+02	2.87e+06	0.00e+00
	100	0.00e+00	7.77e-24	6.58e-07	6.67e+02	3.01e+03	0.00e+00
f_8	10	1.31e-07	8.46e-15	2.41e-09	1.63e-06	8.49e-01	0.00e+00
	30	3.80e-07	8.57e-19	4.21e-04	5.89e-05	8.97e-02	0.00e+00
	100	1.04e-07	7.31e-24	4.45e-02	7.51e-04	7.18e-03	0.00e+00
f_9	10	8.26e-90	2.07e-11	5.11e-07	6.06e-16	7.62e+00	0.00e+00
	30	4.13e-135	4.93e+41	9.70e-08	1.45e-13	2.29e+00	0.00e+00
	100	1.83e-238	7.09e-21	1.11e-11	1.00e-13	0.000452	0.00e+00
f_{10}	10	4.77e-159	3.06e-14	1.30e-09	1.01e-27	2.81e+03	0.00e+00
	30	3.08e-235	1.00e-18	1.91e-09	1.86e-25	7.90e+03	0.00e+00
	100	0.00e+00	7.75e-24	1.36e-07	2.09e-20	1.86e+02	0.00e+00
f_{11}	10	4.77e-159	3.06e-14	1.30e-09	1.01e-27	2.81e+03	0.00e+00
	30	3.08e-235	1.00e-184	1.91e-09	1.86e-25	7.90e+03	0.00e+00
	100	0.00e+00	7.75e-24	1.36e-07	2.09e-20	1.86e+02	0.00e+00
f_{12}	10	1.23e-89	2.28e-11	3.98e-07	3.14e-16	8.59e+00	0.00e+00
	30	1.96e-135	8.62e-16	5.45e-08	3.57e-15	2.04e+00	0.00e+00
	100	2.02e-236	7.24e-21	5.93e-10	2.20e-13	2.15e-02	0.00e+00
f_{13}	10	1.85e-52	2.05e-11	1.00e-03	9.33e-13	3.12e+00	0.00e+00
	30	1.52e-60	8.45e-16	1.899287	9.83e-06	2.530699	0.00e+00
	100	3.66e-75	7.22e-21	12.44531	3.553165	3.492325	0.00e+00
f_{14}	10	8.22e-162	2.72e-14	2.27e-11	1.46e-29	4.61e+01	0.00e+00
	30	1.34e-237	9.59e-19	3.58e-12	9.06e-28	9.47e+00	0.00e+00
	100	0.00e+00	7.59e-24	1.58e-11	7.95e-24	6.69e-02	0.00e+00
f_{15}	10	2.89e-163	2.31e-14	1.19e-13	2.15e-29	2.54e-01	0.00e+00
	30	5.97e-239	9.09e-19	2.40e-14	1.89e-28	1.02e-01	0.00e+00
	100	0.00e+00	7.40e-2	1.25e-13	2.57e-24	5.22e-04	0.00e+00

比算法,在2个测试函数上的结果分别等同于BOA与GWO算法;当维度为30时,ICCOA在 $f_4 \sim f_{15}$ 等12个测试函数上最优值达到了理论最优值,求解精度优于对比算法,在 f_1, f_2 上与BOA持平,在 f_3 上与GWO、BOA持平;当维度为100时,GWO算法与ICCOA算法的求解精度在8个函数上均达到了最优,但是ICCOA

算法在剩下4个函数上的结果优于GWO算法;此外,ICCOA算法在10、30、100维下,在 $f_2 \sim f_{15}$ 函数上达到终止条件时均得到了函数的理论最优值,其余算法的收敛结果均大于ICCOA的数值结果,未达到函数的理论最优值,即未找到函数的最优解.由此表明ICCOA算法的寻优精度高于其他几个对比算法.从

表3 D = 100时6种算法性能分析

函数	指标	GWO	BOA	COA	HFPSO	FLSLA	ICCOA
f_1	mean	1.03e+00	2.16e+00	5.87e+00	3.47e+00	3.96e+00	5.63e-01
	std	8.18e-02	3.01e-01	3.44e+00	2.19e+00	2.09e+00	2.24e-02
	min	1.55e-14	8.88e-16	1.83e-04	2.39e-13	1.83e-03	8.88e-16
f_2	mean	5.04e+01	8.19e+01	1.34e+02	3.77e+01	2.67e+02	3.02e+01
	std	2.19e+00	5.40e+00	1.97e+01	9.87e+00	4.32e+01	7.25e-01
	min	0.00e+00	0.00e+00	4.50e-03	5.57e-03	7.36e-03	0.00e+00
f_3	mean	8.04e+01	2.93e+02	1.88e+02	1.68e+02	2.15e+02	4.01e+01
	std	8.14e+00	1.96e+02	8.27e+01	2.68e+02	7.07e+01	1.63e+00
	min	0.00e+00	0.00e+00	1.21e+00	1.71e+02	1.47e-03	0.00e+00
f_4	mean	1.48e+01	2.53e+01	3.91e+01	1.06e+01	7.73e+01	8.89e+00
	std	6.65e-01	1.74e+00	5.68e+00	2.87e+00	1.26e+01	2.15e-01
	min	0.00e+00	7.26e-24	3.00e-15	2.17e-26	4.87e-06	0.00e+00
f_5	mean	8.26e+00	1.49e+01	2.42e+01	1.91e+01	2.82e+01	4.69e+00
	std	5.43e-01	1.56e+00	7.97e+00	9.83e+00	6.18e+00	1.47e-01
	min	6.9e-233	1.32e-51	1.45e-02	1.48e-01	4.68e-04	0.00e+00
f_6	mean	5.61e-01	1.12e+00	1.47e+00	4.21e-01	2.90e+00	3.43e-01
	std	2.51e-02	8.84e-02	2.14e-01	1.14e-01	4.68e-01	8.24e-03
	min	0.00e+00	7.03e-24	8.9e-17	6.93e-27	2.95e-07	0.00e+00
f_7	mean	5.48e+09	3.06e+09	1.46e+10	4.06e+09	2.93e+10	3.37e+09
	std	2.43e+08	8.68e+07	2.11e+09	1.03e+09	4.67e+09	8.14e+07
	min	0.00e+00	7.77e-24	6.89e-07	1.00e+03	2.81e+03	0.00e+00
f_8	mean	2.85e+08	1.32e+08	5.34e+08	1.03e+08	1.81e+09	1.32e+08
	std	1.74e+07	3.29e+06	5.39e+07	9.33e+06	2.30e+08	2.27e+06
	min	4.23e-07	7.97e-24	3.94e+05	1.21e+00	7.17e+01	0.00e+00
f_9	mean	2.25e+00	4.66e+00	6.88e+00	4.62e+00	9.86e+00	1.49e+00
	std	1.25e-01	4.56e-01	1.50e+00	2.31e+00	2.34e+00	4.66e-02
	min	0.00e+00	2.22e-26	7.17e-22	5.26e-45	2.15e-04	0.00e+00
f_{10}	mean	6.53e+07	4.43e+07	1.64e+08	3.06e+07	4.58e+08	3.86e+07
	std	8.19e+06	1.19e+06	1.58e+07	1.68e+06	5.45e+07	7.36e+05
	min	0.00e+00	7.8e-24	1.19e-07	2.52e-20	1.05e+03	0.00e+00
f_{11}	mean	6.58e+08	4.41e+08	1.84e+09	4.96e+08	3.64e+09	4.30e+08
	std	2.80e+07	1.39e+07	2.61e+08	1.32e+08	5.67e+08	1.04e+07
	min	2.9e-236	7.29e-21	6.05e-10	3.33e+00	1.96e-02	0.00e+00
f_{12}	mean	1.14e+02	1.97e+02	3.44e+02	2.19e+02	4.97e+02	7.36e+01
	std	6.33e+00	1.65e+01	7.50e+01	1.07e+02	1.15e+02	2.30e+00
	min	3.66e-75	7.22e-21	12.44531	3.55e+00	3.49e+00	0.00e+00
f_{13}	mean	1.34e+01	5.05e+00	1.32e+01	8.82e+00	1.73e+01	2.02e+00
	std	2.67e+00	4.96e-01	2.30e+01	1.20e+01	1.56e+01	7.43e-02
	min	0.00e+00	7.56e-24	1.36e-11	6.18e-24	2.30e+02	0.00e+00
f_{14}	mean	1.08e+05	1.26e+05	3.05e+05	8.05e+04	6.21e+05	7.28e+04
	std	4.63e+03	5.97e+03	4.25e+04	2.11e+04	9.87e+04	1.78e+03
	min	0.00e+00	7.36e-24	9.13e-14	2.47e-24	8.21e-04	0.00e+00
f_{15}	mean	6.65e+02	1.02e+03	1.90e+03	4.96e+02	3.71e+03	4.38e+02
	std	2.86e+01	6.00e+01	2.63e+02	1.33e+02	5.81e+02	1.05e+01
	min	1.8e-238	7.09e-21	1.11e-11	1.11e-13	4.52e-04	0.00e+00

15个测试函数上看,与其他5种算法相比,各维度下ICCOA算法的优化性能都有一定优势. 另外可以看出,随着维度的增加,ICCOA算法的优化性能依然占据优势,具有良好的高维可扩展性.

表3给出了6种算法在100维函数上的测试结果,采取实验结果均值、标准差、最优值作为评价指标进行算法性能分析. 由表3数值可以看出:在 f_1 上,BOA算法与ICCOA算法在最优值上是最好的,在 f_4 、 f_6 、 f_9 、 f_{10} 、 f_{13} 及 f_{14} 上,GWO算法与ICCOA算法在最优值上同为最优,且在 f_2 和 f_3 上,ICCOA算法、GWO算法及BOA算法在最优值指标上都是最优的,故3种算

法优化结果更好一些,但是ICCOA算法的平均值和标准差在3种算法中更优,故ICCOA算法的优化性能更好. 值得一提的是,在 f_5 、 f_{11} 、 f_{12} 和 f_{15} 上,ICCOA算法的平均值、标准差和最优值都比其他5种算法的结果好. 在 f_7 和 f_8 上,BOA算法、HFPSO算法在平均值的寻优上均取得了最优结果,但是两种算法均未达到理论最优值,而ICCOA算法的最差值达到了最优,且标准差结果更小,算法更稳定,故ICCOA算法的性能优势强于BOA算法和HFPSO算法. 综上,从100维函数上的实验结果可知,所提出ICCOA算法的优化性能相对优异.

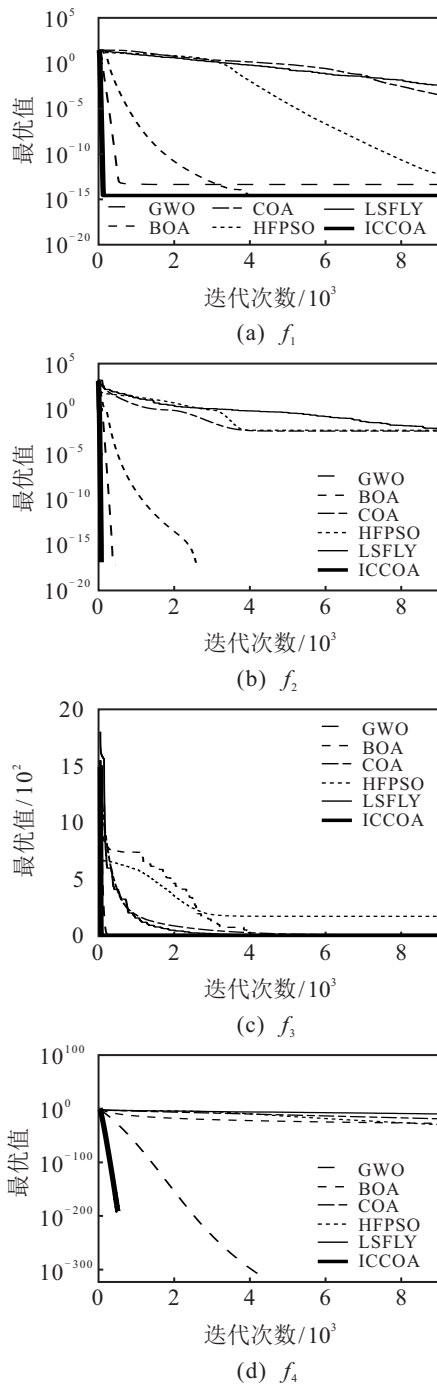


图2 100维度 $f_1 \sim f_4$ 测试函数收敛曲线

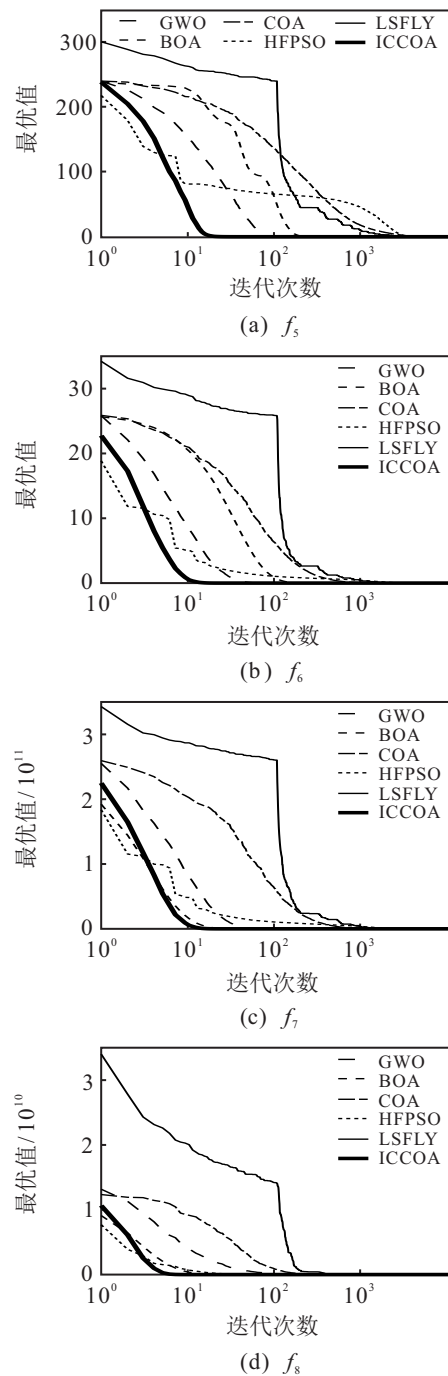


图3 100维度 $f_5 \sim f_8$ 测试函数收敛曲线

2) 收敛性能分析.

为了更直观地看出ICCOA算法的收敛速度、局部搜索能力和全局搜索能力,给出6种算法在100维度下的测试函数收敛曲线,为了可视化结果更加清晰,对部分函数曲线分别进行对数处理.由图2~图4

可见,ICCOA算法的收敛速度均优于其他5种对比算法,该算法总是最早收敛到最优结果,特别是在函数 f_1 、 f_2 、 f_4 、 f_5 、 f_9 和 f_{12} 等函数上,ICCOA算法的收敛速度大幅度优于对比算法.

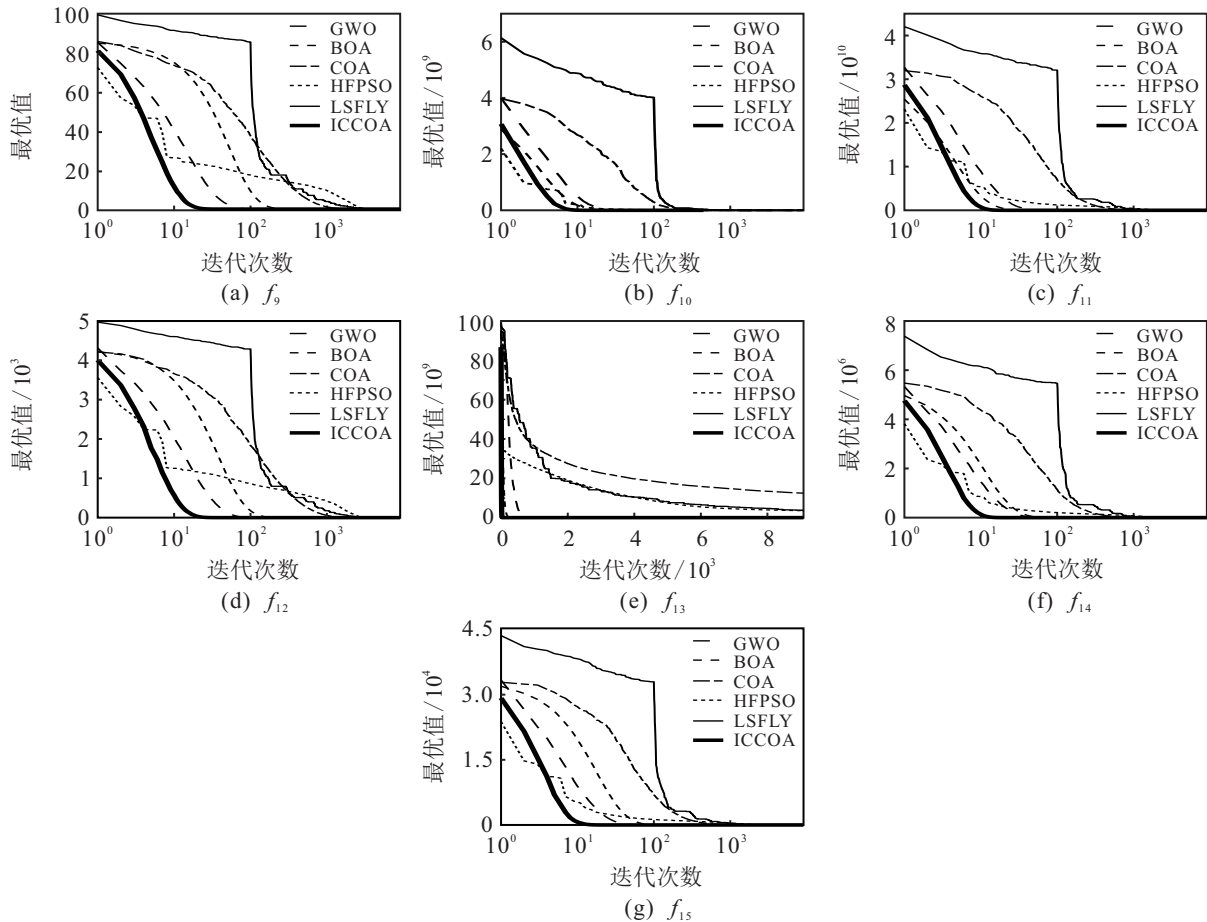


图4 100维度 $f_9 \sim f_{15}$ 测试函数收敛曲线

从整体情况看,ICCOA算法在15个测试函数上的收敛性能最优,再一次验证ICCOA算法的改进策略是有效的.其原因是由于ICCOA算法融入了反时限衰减因子,提升了算法的全局勘探能力,且在种群迁移后期引入混沌映射操作,增强了种群的多样性,种群中更优个体的信息得到有效利用,使得ICCOA算法的收敛速度得到了很大幅度的提升,故ICCOA算法不管在单峰函数还是多峰函数上,与其他5种算法相比,都具有更优秀的优化性能.综上,本文对ICCOA算法的改进具有有效性和可行性.

4 基于ICCOA的BP神经网络参数优化

鉴于ICCOA通过反时限衰减算子和混沌扰动操作可以有效平衡算法的全局搜索和局部开发能力,提高种群多样性,将ICCOA在解决复杂优化问题具有的性能优势和郊狼种群独特的进化策略引入到BP

神经网络参数优化过程中,提出一种基于ICCOA方法的BP神经网络参数优化方法——ICCOABP.

4.1 设计步骤

针对分类问题,以神经网络的分类准确率最大化为优化原则,将神经网络训练转换为最优化问题,利用智能群体算法进行目标问题求解,其数学模型为

$$\begin{aligned} \min F(\omega, b); \\ \text{s.t. } \omega \in [\omega_{\min}, \omega_{\max}], b \in [b_{\min}, b_{\max}]. \end{aligned} \quad (19)$$

其中: ω 为BP神经网络权值, b 为阈值.

设训练集为 X ,神经网络个体分类器 x 的输入层节点为 a ,隐含层节点为 b ,输出层节点为 c ,个体维度为 D ,具体实现步骤如下.

step 1: 数据预处理及相应参数的设置.

step 2: 郊狼种群的初始化.利用BP神经网络进行初始的网络训练得到网络权值和阈值,进行实值编

码,得到初始个体组成的群体 $x^{p,t}$ 及群体组成的种群 x^t ,有

$$x^{p,t} = [x_1^{p,t}, x_2^{p,t}, \dots, x_{N_c}^{p,t}], i \in (1, 2, \dots, N_c);$$

$$x^t = [x_1^t, x_2^t, \dots, x_{N_p}^t], i \in (1, 2, \dots, N_p). \quad (20)$$

其中: $x_i^{p,t}$ 、 $x_j^{j,t}$ 分别为 t 时刻 p 群中第 i 个体、第 j 群体; 个体为待优化的BP神经网络预测参数.

step 3: 初始种群所有个体适应度的计算.将分类准确率作为个体的适应度值 f_i ,有

$$k_i = \begin{cases} 1, & y_i = o_i; \\ 0, & y_i \neq o_i. \end{cases}$$

$$f_i = \sum_{i=1}^l \frac{k_i}{l}. \quad (21)$$

其中: l 为网络输入样本数目, y_i 为BP神经网络第 i 个样本的期望输出, o_i 为第 i 个样本的预测输出, $i \in \{1, 2, \dots, l\}$.

step 4: 更新. 计算种群中分类准确率最大的个体 $\alpha^{p,t}$ 与群体文化趋势 $\text{cult}^{p,t}$, 结合式(9)、(11)、(12)更新个体,选择适应度最优的个体作为当前个体,执行郊狼算法的出生和死亡操作.

step 5: 群体变迁.

step 6: 混沌干扰. 检测阈值 R 是否满足概率 r , 满足则找出当前分类准确率最差的群体 p , 通过 Tent 映射对种群 $1/N_c$ 的最差个体进行搜索以获得较优的个体并取代.

step 7: 年龄更新. 群体更新后,对种群中所有个体年龄 $\text{age}_c^{p,t}$ 依次加1更新.

step 8: 判定是否满足终止条件. 若满足则输出最优的个体 $x_i^{p,t}$ 及参数 ω 、 b , 反之转至 step 4 继续执行优化.

4.2 仿真实验

本文从UCI分类数据库中选取6个常用数据集进行分类效果对比测试,包括乳腺癌病例、鸢尾花分类、助教评估、心脏病、红酒和糖尿病等数据集,具体信息如表4所示. 实验中数据集按1:1:1利用分层采样的方式划分为训练样本、验证样本和测试样本. 考虑到量纲等差异对数据集进行归一化处理^[9], 计算公式为

$$X_{i,j} = \frac{x_{i,j} - x_j^{\min}}{x_j^{\max} - x_j^{\min}}. \quad (22)$$

其中: x_j^{\max} 和 x_j^{\min} 分别为第 j 列最大值和最小值, $X_{i,j}$ 为归一化后的样本.

标准的BP神经网络利用单一的网络进行优化,所提出的ICCOABP方法产生了多个神经网络进行

表4 UCI中6组数据集物理属性

数据集	类别数目	特征个数	样本总数	训练/验证数	测试数	隐层数
DBT	2	8	768	256	256	8
Iris	3	4	150	50	50	6
TAE	3	5	151	50	51	8
HDA	2	13	270	90	90	6
Wine	3	13	178	60	58	12
BCC	2	9	683	228	227	8

学习优化,因此为了分析算法性能,与标准神经网络方法(SNN)以及基于遗传算法的BP神经网络参数优化方法(GABP)进行比较. 训练过程中,针对同一数据集将算法的模型参数设置为相同的值. 其中: SNN、GABP迭代次数设置为3000,ICCOABP的终止条件设置为3000,种群规模均设置为25,学习率为0.2. 分别对6组实验数据进行30次实验,并以30次实验的测试集平均值、标准差、最小值以及最大值作为实验最终评价指标,实验结果如表5所示.

表5 实验结果对比

数据集	算法	评价指标			
		avg	std	min	max
DBT	SNN	72.48	2.57	67.32	77.17
	GABP	72.52	2.04	68.90	77.17
	ICCOABP	73.37	2.56	69.69	79.53
Iris	SNN	94.37	2.36	87.50	97.92
	GABP	95.28	3.18	87.50	100.00
	ICCOABP	95.35	2.22	89.58	100.00
TAE	SNN	49.00	5.68	36.17	61.70
	GABP	47.16	7.37	38.30	63.83
	ICCOABP	49.97	5.64	40.30	63.83
HDA	SNN	74.00	4.78	81.11	63.33
	GABP	76.70	4.20	83.33	68.89
	ICCOABP	76.96	4.09	83.33	68.89
Wine	SNN	96.72	2.05	93.10	100.00
	GABP	96.26	2.48	91.38	100.00
	ICCOABP	97.01	1.83	93.10	100.00
BCC	SNN	94.61	1.76	91.63	97.80
	GABP	94.96	1.61	91.63	96.92
	ICCOABP	95.71	1.56	92.70	98.24

由表5可见,在不同特征数据集下的分类任务中,ICCOABP得到的分类结果对比SNN、GABP而言更具有优势,分类准确率的平均值均达到了最高,表明ICCOABP算法具有较好的平均性能. 标准差在5组数据集上也均高于SNN和GABP,故ICCOABP算法的稳定性更高;同时,在大部分数据集上ICCOABP的最小值、最大值指标也优于SNN和GABP.

为进一步直观地观察上述结果并验证数据的可靠性,对两种方法的30次预测准确率实验结果进行箱线图的可视化分析,横坐标代表两种算法,纵坐标代表预测准确率,上三角表示预测准确率平均值,具体如图5所示.

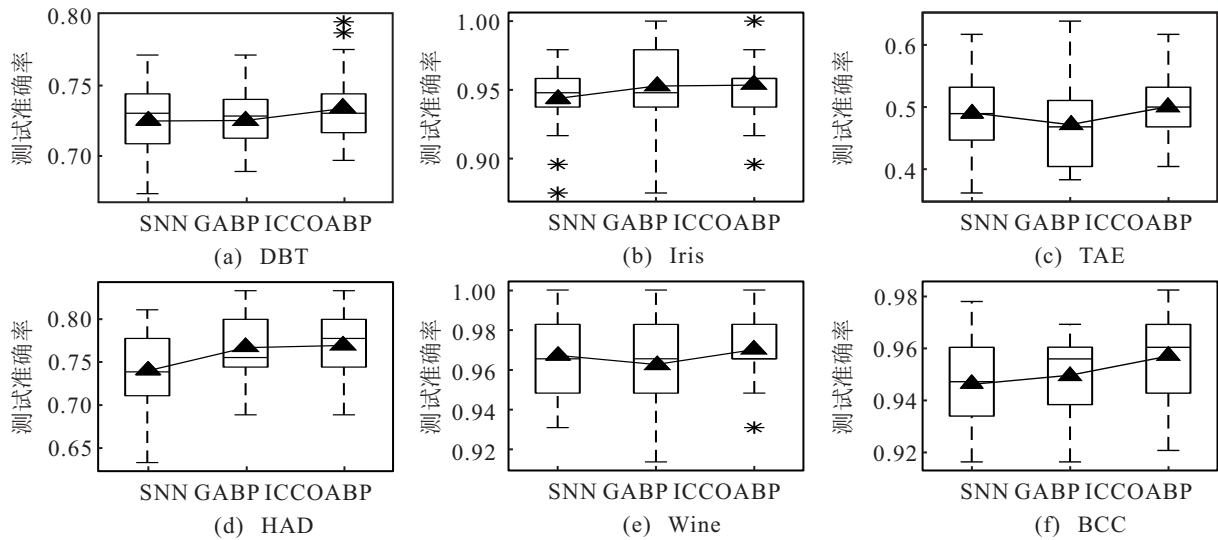


图5 箱线图

由图5可见,ICCOABP的预测平均准确率均高于SNN和GABP,表明基于反时限混沌郊狼算法的BP神经网络参数优化是有效的.此外,ICCOABP在6个数据集上30次实验结果的中心位置更居中,表明算法经多次迭代后产生的参数可以得到相对稳定的预测准确率.同时,ICCOABP在DBT、TAE、HDA、Wine等4个数据集上的四分位间距较短,分类准确率更集中.考虑到箱线图中显示DBT、Iris、Wine数据集上SNN与ICCOABP分别存在异常点,故删除这些异常数据后重新计算,得到表6.

表6 剔除异常值后3组实验结果对比

数据集	算法	评价指标			
		avg	std	min	max
DBT	SNN	72.34	2.54	67.32	77.17
	GABP	72.46	1.98	68.90	77.17
	ICCOABP	72.96	1.90	69.69	77.56
Iris	SNN	94.75	1.82	91.67	97.92
	GABP	95.06	3.16	87.50	100.00
	ICCOABP	95.37	1.37	91.67	97.92
Wine	SNN	96.85	1.98	93.10	100.00
	GABP	96.20	2.50	91.38	100.00
	ICCOABP	97.15	1.71	94.83	100.00

结合表6与上述结果综合分析:ICCOABP的4项指标达到了最优,具有较好的平均性能;标准差也达到了最优,表明算法的稳定性高,鲁棒性强;最小值指标代表算法的最坏分类效能,效能优表明ICCOABP算法更适用于实际工程领域,可以尽可能保证算法的最小错判率,降低工程生产的经济损失;最大值指标较优表明在实际工程应用中更可能给工程带来最大的经济保障,实际应用中具有较好的工程应用前景.

5 结论

本文从智能仿生优化算法的角度出发,围绕算法的改进与应用开展了研究,通过理论分析和数值实验形成如下结论:

1) 为改善传统郊狼算法的性能,提出了一种反时限混沌郊狼优化算法(ICCOA),该方法通过引入反时限权重和混沌机制,改进了郊狼个体更新过程,并利用混沌映射的遍历性和均匀性实现了群体位置的更新,数值实验结果表明,ICCOA有效提高了郊狼优化算法的收敛速度与全局寻优性能.

2) 为了更好地发挥ICOA求解复杂优化问题优势,将ICOA中的郊狼种群进化策略引入到BP神经网络参数优化过程中,提出了一种结合ICCOA与BP神经网络方法——ICCOABP,并应用于分类任务,实验结果表明,ICOABP有效实现了BP神经网络权值和阈值的优化,与SNN、GABP等算法相比具有更高的分类性能.

本文所做工作是融合优化算法与机器学习探索的一次有益尝试,数值实验结果充分表明了ICCOA算法和ICOABP算法的有效性和性能优势.后续研究将围绕基于ICCOA算法的深度神经网络超参数的优化方法,以及ICOABP机器学习工具箱的研发等方向继续深入开展.

参考文献(References)

[1] Pierezan J, Coelho L S. Coyote optimization algorithm: A new metaheuristic for global optimization problem[C]. Proceedings of the IEEE Congress on Evolutionary Computation. Brazil: Riode Janeiro, 2018: 2633-2640.
 [2] Salcedosanz S. Modern meta-heuristics based on nonlinear physics processes: A review of models and design procedures[J]. Physics Reports, 2016: 1-70.

- [3] Wolpert D H, Macready W G. No free lunch theorems for optimization[J]. IEEE Transactions on Evolutionary Computation, 1997, 1(1): 67-82.
- [4] 张新明, 付子豪, 陈海燕, 等. 全局引导和相互作用的郊狼优化算法及其应用[J]. 计算机应用研究, 2019: 37(9): 1-7.
(Zhang X M, Fu Z H, Chen H Y, et al. Global guidance and interaction of coyote optimization algorithm and its application[J]. Computer Application Research, 2019: 37(9): 1-7.)
- [5] 张新明, 王豆豆, 陈海燕, 等. 强化最优和最差狼的郊狼优化算法及其QAP应用[J]. 计算机应用, 2019: 39(10): 2985-2991.
(Zhang X M, Wang D D, Chen H Y, et al. Coyote optimization algorithm and its QAP application for strengthening optimal and worst wolves[J]. Computer Application, 2019, 39(10): 2985-2991.)
- [6] Cheng L. 学习率衰减方法[DB/OL]. (2019-06-24) [2020-04-11]. <https://blog.csdn.net/weixin.39875161/article/details/93423883>.
- [7] Pitt W C, Box P W, Knowlton F F. An individual-based model of canid populations: Modelling territoriality and social structure[J]. Ecological Modelling, 2003, 166(1/2): 109-121.
- [8] Poessel S A, Gese E M, Young J K, et al. Influence of habitat structure and food on patch choice of captive coyotes[J]. Applied Animal Behaviour Science, 2014, 157: 127-136.
- [9] Shi Y H, Eberhart R C. Empirical study of particle swarm optimization[J]. Proceedings of the IEEE Congress on Evolutionary Computation, 1999, 3: 101-106.
- [10] 赵欣. 不同一维混沌映射的优化性能比较研究[J]. 计算机应用研究, 2012, 29(3): 913-915.
(Zhao X. Comparative study on optimization performance of different one-dimensional chaotic maps[J]. Computer Application Research, 2012, 29(3): 913-915.)
- [11] Tang D, Jin Y, Dong S, et al. A levy flight-based shuffled frog-leaping algorithm and its applications for continuous optimization problems[J]. Applied Soft Computing, 2016, 49: 641-662.
- [12] Avdilek I B. A hybrid firefly and particle swarm optimization algorithm for computationally expensive numerical problems[J]. Applied Soft Computing, 2018, 66: 232-249.
- [13] Mirjalili S, Mirjalili S M, Lewis A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61.
- [14] Arora S, Singh S. Butterfly optimization algorithm: A novel approach for global optimization[J]. Soft Computing, 2018, 23(3): 715-734.
- [15] 李英海, 周建中, 杨俊杰, 等. 一种基于阈值选择策略的改进混合蛙跳算法[J]. 计算机工程与应用, 2007, 43(35): 19-21.
(Li Y H, Zhou J Z, Yang J J, et al. An improved hybrid leapfrog algorithm based on threshold selection strategy[J]. Computer Engineering and Application, 2007, 43(35): 19-21.)
- [16] Maitra M, Chatterjee A. A hybrid cooperative-comprehensive learning based PSO algorithm for image segmentation using multilevel thresholding[J]. Expert Systems with Applications, 2008, 34(2): 1341-1350.
- [17] Eberhart R, Kennedy J. Particle swarm optimization[C]. IEEE Int Conference on Neural Networks. Perth: IEEE, 1995: 1942-1948.
- [18] Yang X S. Firefly algorithms for multimodal optimization[C]. International Symposium on Stochastic Algorithms. Berlin: Springer Heidelberg, 2009: 169-178.
- [19] 赵世杰, 高雷阜, 于冬梅, 等. 带混沌侦查机制的蚁狮优化算法优化SVM参数[J]. 计算机科学与探索, 2016, 10(5): 722-731.
(Zhao S J, Gao L F, Yu D M, et al. Ant lion optimization algorithm with chaotic detection mechanism to optimize SVM parameters[J]. Computer Science and Exploration, 2016, 10(5): 722-731.)

作者简介

刘威(1996—), 男, 副教授, 博士, 从事机器学习、深度神经网络、矿业系统工程等研究, E-mail: lv8218218@126.com;

付杰(1996—), 女, 硕士生, 从事机器学习、深度神经网络的研究, E-mail: 2830380955@qq.com;

周定宁(1993—), 男, 硕士生, 从事机器学习、深度神经网络的研究, E-mail: zhou_dingning@163.com;

王薪予(1994—), 男, 硕士生, 从事机器学习、深度神经网络的研究, E-mail: 918716957@qq.com;

成秘(1995—), 女, 硕士生, 从事机器学习、计算机视觉的研究, E-mail: 603359476@qq.com;

黄敏(1994—), 女, 硕士生, 从事机器学习、计算机视觉的研究, E-mail: 978668293@qq.com;

靳宝(1996—), 男, 硕士生, 从事机器学习、计算机视觉、自然语言处理的研究, E-mail: 1534798380@qq.com;

牛英杰(1998—), 男, 硕士生, 从事机器学习、深度神经网络的研究, E-mail: 1805776973@qq.com.

(责任编辑: 郑晓蕾)