智能系统学报
CAAI TRANSACTIONS ON INTELLIGENT SYSTEMS

融合振幅随机补偿与步长演变机制的改进原子搜索优化算法

刘威, 郭直清, 刘光伟, 靳宝, 王东

引用本文:
刘威,郭直清,刘光伟,靳宝,王东. 融合振幅随机补偿与步长演变机制的改进原子搜索优化算法[J]. 智能系统学报, 2022, 17(3): 602–616.
LIU Wei,GUO Zhiqing,LIU Guangwei,JIN Bao,WANG Dong. Improved atom search optimization by combining amplitude random compensation and step size evolution mechanism[J]. *CAAI Transactions on Intelligent Systems*, 2022, 17(3): 602–616.

在线阅读 View online: https://dx.doi.org/10.11992/tis.202103033

DOI: 10.11992/tis.202103033
网络出版地址: https://kns.cnki.net/kcms/detail/23.1538.TP.20220418.1501.004.html

融合振幅随机补偿与步长演变机制的改进原子搜索优化算法

刘威[1,2,3], 郭直清[1,2,3], 刘光伟[4], 靳宝[1,2,3], 王东[4]

（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. 辽宁工程技术大学 数学与系统科学研究所, 辽宁 阜新 123000; 4. 辽宁工程技术大学 矿业学院, 辽宁 阜新 123000）

摘　要: 针对原子优化算法寻优精度弱且易陷入局部极值的问题, 本文从种群多样性、参数适应性和位置动态性角度提出一种融合混沌优化、振幅随机补偿和步长演变机制改进的原子搜索优化算法 (improved atom search optimization, IASO), 并将其成功应用于分类任务。首先, 引入帐篷映射 (Tent 混沌) 增强原子种群在搜索空间中的分布均匀性; 其次, 通过构建振幅函数对算法参数进行随机扰动并加入步长演变因子更新原子位置, 以增强算法全局性和收敛性; 最后, 再将改进算法应用于误差反馈神经网络 (BP 神经网络) 参数优化。通过与 6 种元启发式算法在 20 个基准测试函数下的数值实验对比表明: IASO 不仅在求解多维基准函数上具有好的寻优性能, 且在对 BP 神经网络参数进行优化时相较于 2 种对比算法具有更高的分类精度。

关键词: 元启发式算法; 原子搜索优化算法; Tent 混沌优化; 振幅随机补偿; 步长演变机制; BP 神经网络参数优化; 分类; 机器学习
中图分类号: TP18　　**文献标志码**: A　　**文章编号**: 1673−4785(2022)03−0602−15

中文引用格式: 刘威, 郭直清, 刘光伟, 等. 融合振幅随机补偿与步长演变机制的改进原子搜索优化算法 [J]. 智能系统学报, 2022, 17(3): 602–616.
英文引用格式: LIU Wei, GUO Zhiqing, LIU Guangwei, et al. Improved atom search optimization by combining amplitude random compensation and step size evolution mechanism[J]. CAAI transactions on intelligent systems, 2022, 17(3): 602–616.

Improved atom search optimization by combining amplitude random compensation and step size evolution mechanism

LIU Wei[1,2,3], GUO Zhiqing[1,2,3], LIU Guangwei[4], JIN Bao[1,2,3], WANG Dong[4]

(1. College of Science, Liaoning Technical University, Fuxin 123000, China; 2. Institute of Intelligent Engineering and Mathematics, Liao ning Technical University, Fuxin 123000, China; 3. Institute of Intelligent Engineering and Methematics, Liaoning Technical University, Fuxin 123000, China; 4. College of Mines, Liaoning Technical University, Fuxin 123000, China)

Abstract: The weak optimization accuracy of the atom search optimization algorithm can easily fall into a local extremum owing to population diversity, parameter adaptability, and position dynamics. To overcome this challenge, we propose an improved ASO algorithm (IASO) by integrating chaos optimization, amplitude random compensation, and step size evolution mechanism and successfully apply it to classification tasks. First, tent chaos is introduced to enhance the distribution uniformity of atomic population in the search space. Then, an amplitude function is constructed to randomly perturb the algorithm parameters, and the step evolution factor is added to update the atomic position to enhance the globality and convergence of the algorithm. Finally, the improved algorithm is applied to the parameter optimization of the error feedback BP neural network. Compared with the numerical calculations of six metaheuristic algorithms under 20 benchmark functions, the experimental results indicate that IASO not only shows a good optimization performance in solving multidimensional benchmark functions but also a higher classification accuracy than two comparison algorithms in optimizing the BP neural network parameters.

Keywords: meta-heuristics algorithms; atom search optimization; tent chaos optimization; amplitude random compensation; step size evolution mechanism; parameter optimization of BP neural network; classification; machine learning

收稿日期: 2021−03−24.　**网络出版日期**: 2022−04−19.
基金项目: 国家自然科学基金项目 (51974144, 51874160); 辽宁省教育厅项目 (LJKZ0340); 辽宁工程技术大学学科创新团队资助项目 (LNTU20TD-01, LNTU20TD-07).
通信作者: 刘威. E-mail: lv8218218@126.com.

元启发式算法是指研究者受仿生学启发, 从自然界中的随机现象获取灵感, 将随机算法与局部算法相结合来求解复杂优化问题的一类算法[1]。

此类算法相对于启发式算法的最大改进在于引入了随机因素的影响, 从而使算法存在一定概率跳出局部最优, 更有可能得到问题全局最优解, 同时由于其对目标函数、初始值等无任何特殊要求, 因此成为了最优化问题研究的热点问题之一。根据算法启发机制不同, 元启发式算法可归结于两类: 模仿生物学过程的算法和基于物理学原理的算法。其中模仿生物学过程的算法又可分为两类: 基于生物进化的演化算法和基于动物社会性行为的群智能算法。基于生物进化的演化算法主要以遗传算法 (genetic algorithm, GA)[2] 为代表, 同时还有进化策略 (evolutionary strategies, ES)[3]、文化基因算法 (memetic algorithm, MA)[4] 等; 基于动物社会性行为的群智能算法是近年来元启发式算法研究的热点, 有模拟鸟群捕食的粒子群算法 (particle swarm optimization, PSO)[5]、基于乌鸦智能行为的乌鸦搜索算法 (crow search algorithm, CSA)[6]、模拟樽海鞘聚集行为的樽海鞘群算法 (Salp swarm algorithm, SSA)[7]、模拟蝴蝶觅食和求偶行为的蝴蝶优化算法 (butterfly optimization algorithm, BOA)[8]、模拟飞蛾飞行行为的飞蛾扑火优化算法 (moth-flame optimization, MFO)[9] 等; 基于物理学原理的算法有模仿固体退火的模拟退火算法 (simulated annealing, SA)[10]、模仿万有引力原理的引力搜索算法 (gravitational search algorithm, GSA)[11]、模仿多元宇宙理论中黑洞、白洞及虫洞概念的多元宇宙优化算法 (multi-verse optimizer, MVO)[12] 等。

原子搜索优化算法 (atom search optimization, ASO) 是 Zhao 等[13-14] 受分子动力学启发提出的一种以物理学为灵感的基于原子运动的新型智能元启发式优化算法。该算法模仿由相互作用和约束力控制的原子运动, 通过 Lennard-Jones(L-J) 势产生的相互作用力和原子共价键产生的约束力共同作用于原子, 使不同质量的原子具有不同的速度和加速度, 从而不断地更新原子所在位置, 直到原子处于最优位置时, 算法迭代完成。由于其启发机制简单、参数少、探索 (exploration) 和挖掘 (exploitation) 性强等特点已被应用于地下水中的弥散系数估计[13]、水文地质参数估计[14]、自动聚类[15]、燃料电池模型参数估计[16] 等多个领域。

为提高 ASO 算法的收敛速度、求解精度及跳出局部最优能力, 本文从原子群多样性、模型参数设置和原子位置更新角度提出了一种融合混沌优化、振幅随机补偿和步长演变机制的模拟原子位置更新过程的改进 ASO 算法 (improved atom search optimization, IASO), 并将其应用于 BP 神经网络参数优化。通过对 10 个可变维基准测试函数在不同维度下以及 10 个固定多维度基准测试函数与 5 种元启发算法进行仿真实验对比, 数值实验结果不仅验证了 IASO 相对于传统 ASO 算法和对比算法具有更好的寻优精度和全局性能, 而且在对 BP 神经网络参数优化时表现出更高的分类性能。

1　原子搜索优化算法 (ASO)

对于 ASO 算法, 其基本理论主要包含 3 个部分[13-14]: 原子运动约束方程、L-J 势产生的相互作用力以及键长势引起的约束力。假设一个分子系统是由N个原子构成的 D 维空间, $x_i^d(t)$为第i个原子在第 d 个维度下第t次迭代时的位置, $a_i^d(t)$为第i个原子在第 d 个维度下第t次迭代时的加速度, $v_i^d(t)$为第i个原子在第 d 个维度下第t次迭代时的速度, $F_i^d(t)$为第i个原子在第 d 个维度下第t次迭代时由 L-J 势产生的相互作用力, $G_i^d(t)$为第i个原子在第 d 个维度下第t次迭代时由原子共价键产生的约束力。

1.1　原子运动约束方程

ASO 算法中假设原子运动满足牛顿第二定律, 由于原子受 L-J 势产生的相互作用力和原子共价键产生的约束力共同作用, 故带约束的原子运动方程表示为

$$F_i^d(t)+G_i^d(t)=m_i^d(t)a_i^d(t) \tag{1}$$

式中: $F_i^d(t)$为第i个原子在第 d 个维度下第t次迭代时由 L-J 势产生的相互作用力; $G_i^d(t)$为第i个原子在第 d 个维度下第t次迭代时由原子共价键产生的约束力。第i个原子第t次迭代时的加速度为

$$a_i^d(t)=\frac{F_i^d(t)+G_i^d(t)}{m_i^d(t)} \tag{2}$$

式中: $m_i^d(t)$是第t次迭代时第i个原子在第 d 个维度下的质量, 可通过第i个原子的函数适应度值来计算, 即

$$m_i^d(t)=\frac{M_i^d(t)}{\sum_{j=1}^{N}M_j^d(t)} \tag{3}$$

式中$M_i^d(t)=\mathrm{e}^{-\frac{\mathrm{Fit}_i(t)-\mathrm{Fit}_{\mathrm{best}}(t)}{\mathrm{Fit}_{\mathrm{worst}}(t)-\mathrm{Fit}_{\mathrm{best}}(t)}}$。

对于最小化问题, $\mathrm{Fit}_i(t)$是第i个原子在第t次迭代时的函数适应度值, $\mathrm{Fit}_{\mathrm{best}}(t)=\min\limits_{i\in\{1,2,\cdots,N\}}\mathrm{Fit}_i(t)$与$\mathrm{Fit}_{\mathrm{worst}}(t)=\max\limits_{i\in\{1,2,\cdots,N\}}\mathrm{Fit}_i(t)$分别表示在第$t$次迭代时最差原子和最佳原子的目标函数适应值。

在 ASO 算法的整个寻优过程中, 原子的加速度决定了原子所处位置和速度, 其主要来源于两个部分: 由 L-J 势引起的相互作用力和由键长势引起的约束力。但在分子动力学理论框架下, 原

子间的相互排斥相对于平衡距离的变化幅度($r=1.12$)远大于相互吸引的变化幅度(见图 1),这表明了算法随着迭代次数的增加,ASO 并没有获得更多的正吸引和更少的负排斥,这就导致不能直接使用 L-J 势引起的相互作用力和键长势引起的约束力来处理优化问题,因此 Zhao 等[13-14]在分子动力学的原有模型基础上重新定义了原子系统的相互作用力和约束力。

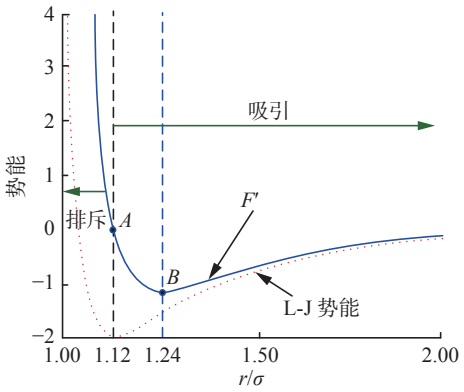

图 1　原子力曲线

Fig. 1　Force curve of atoms

1.2　L-J 势产生的相互作用力

$$F'_{ij}(t)=-\eta(t)[2(h_{ij}(t))^{13}-(h_{ij}(t))^{7}] \tag{4}$$

式中$\eta(t)$是调整排斥和吸引区的深度函数,即

$$\eta(t)=\alpha\left(1-\frac{t-1}{T}\right)^{3}\mathrm{e}^{-\frac{20t}{T}} \tag{5}$$

式中:α为深度权重;T为最大迭代次数。h与F'的关系由图 2 显示,从图 2 中可以看出:对于不同η值,当h介于 0.9~1.12 时发生排斥,当h在 1.12~2 时发生吸引,而当$h=1.12$时发生平衡。从平衡($h=1.12$)开始,吸引力随着h的增加先逐渐增加并达到最大值($h=1.24$),然后再逐渐减小,直到$h=2$时,吸引力约等于零。

因此,为保证 ASO 算法的全局有效性将函数值较小的排斥力下限设置为$h=1.1$,函数值较大的吸引力上限设置为$h=1.24$,即

$$h_{ij}(t)=\begin{cases}h_{\min}, & \dfrac{r_{ij}(t)}{\sigma(t)}<h_{\min}\\ \dfrac{r_{ij}(t)}{\sigma(t)}, & h_{\min}\leqslant\dfrac{r_{ij}(t)}{\sigma(t)}\leqslant h_{\max}\\ h_{\max}, & \dfrac{r_{ij}(t)}{\sigma(t)}>h_{\max}\end{cases} \tag{6}$$

式中:$h_{\min}$和$h_{\max}$分别是h的下限和上限;长度标度

$$\sigma(t)=\left\|x_{ij}(t),\frac{\sum\limits_{j\in K_{\text{best}}}x_{ij}(t)}{K(t)}\right\|_2$$

,K_{best}是原子总体的一个子集,由具有最佳函数适应值的前k个原子组成。

$$K(t)=N-(N-2)\times\sqrt{\frac{t}{T}} \tag{7}$$

$$h_{ij}(t)=\begin{cases}h_{\min}=g_0+g(t)\\ h_{\max}=u\end{cases} \tag{8}$$

式中$g(t)$是使算法保证全局性的漂移算子,表示为

$$g(t)=0.1\times\sin\left(\frac{\pi}{2}\times\frac{t}{T}\right) \tag{9}$$

因此,由 L-J 势产生的相互作用力为

$$F_i^d(t)=\sum_{j\in K_{\text{best}}}\text{rand}_j F_{ij}^d(t) \tag{10}$$

式中:d代表当前搜索空间维度,$d=1,2,\cdots,D$;rand_{ij}是[0,1]中的一个随机数。

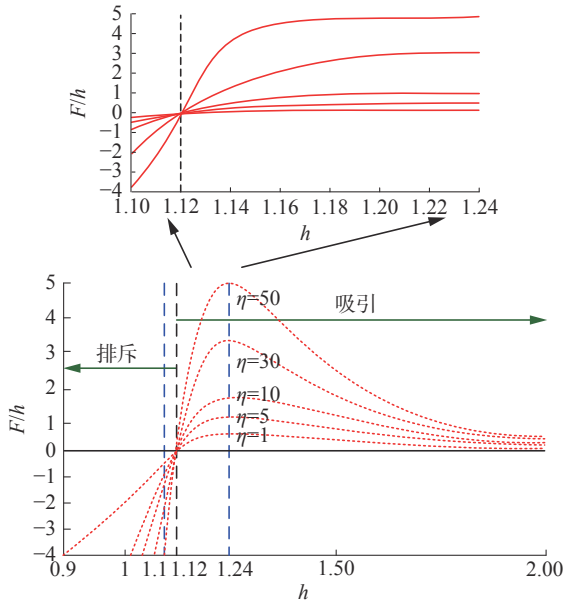

图 2　F'、h和η函数关系

Fig. 2　F', h and η functional relation

1.3　键长势引起的约束力

只依靠 L-J 势引起的相互作用力只能描述简单分子的运动,对于更复杂的分子或原子系统,需引入一种几何约束的分子动力学方法并结合原子内部运动来模拟原子寻优过程。在 ASO 算法中,假设每个原子都与最佳原子有共价键且每个原子都受到来自最佳原子的约束力,则第i个原子约束为

$$\theta_i(t)=\left[|x_i(t)-x_{\text{best}}(t)|^2-b_{i,\text{best}}^2\right] \tag{11}$$

式中:$x_{\text{best}}(t)$是第t次迭代时最佳原子的位置;$b_{i,\text{best}}$是第i个原子与最佳原子之间的固定键长。故第i个原子的约束力为

$$G_i^d(t)=-\lambda(t)\nabla\theta_i^d(t)=-2\lambda(t)(x_i^d(t)-x_{\text{best}}^d(t)) \tag{12}$$

式中:d代表当前搜索空间维度,且$d=1,2,\cdots,D$;$\lambda(t)$为拉格朗日乘子,令$2\lambda\to\lambda$,则共价键引起的约束力可重新定义为

$$G_i^d(t)=-\lambda(t)(x_i^d(t)-x_{\text{best}}^d(t)) \tag{13}$$

式中: d 代表当前搜索空间维度, 且 $d=1,2,\cdots,D$; $\lambda(t)=\beta e^{-\frac{20t}{T}}$, β 是乘数权重。故在相互作用力和几何约束下, 第 i 个原子在 t 时刻的加速度为

$$a_i^d(t)=\frac{F_i^d(t)+G_i^d(t)}{m_i^d(t)}= -\alpha\left(1-\frac{t-1}{T}\right)^3 e^{-\frac{20t}{T}}\frac{(x_i^d(t)-x_j^d(t))}{\|x_i(t),x_j(t)\|_2}\times \sum_{j\in K_{\text{best}}}\frac{\text{rand}_j[2(h_{ij}(t))^{13}-(h_{ij}(t))^7]}{m_i^d(t)}+ \beta e^{-\frac{20t}{T}}\frac{(x_{\text{best}}^d(t)-x_i^d(t))}{m_i^d(t)} \tag{14}$$

为简化 ASO 算法, 在算法的全局寻优过程中, 第 $t+1$ 次迭代时第 i 个原子在第 d 维的位置和速度分别表示为

$$v_i^d(t+1)=\text{rand}_i^d v_i^d(t)+a_i^d(t) \tag{15}$$

$$x_i^d(t+1)=x_i^d(t)+v_i^d(t+1) \tag{16}$$

式中: d 代表当前搜索空间维度, 且 $d=1,2,\cdots,D$; $x_i^d(t)$ 为第 i 个原子在第 d 个维度下第 t 次迭代时的位置; $a_i^d(t)$ 为第 i 个原子在第 d 个维度下第 t 次迭代时的加速度; $v_i^d(t+1)$ 为第 i 个原子在第 d 个维度下第 $t+1$ 次迭代时的速度。

2　改进的原子搜索优化算法 (IASO)

2.1　初始原子种群的混沌优化

最优化问题的解集大多都存在于多参数表示的多维空间中, 没有任何先验知识能够表明全局最优解所处位置, 因此对于元启发式智能优化算法来说, 最优化问题求解结果的好坏往往与初始种群存在较大关系, 初始种群多样性越丰富得到的结果越有可能接近于全局最优解甚至会使得收敛速度加快[17-18]。故初始化种群在整个空间的均匀覆盖性显得极为重要, ASO 算法在设计初就尽量保证种群覆盖整个优化问题的解空间, 但在其种群实际初始化时仍采用随机初始化方法, 这导致初始种群对整个解空间覆盖能力不够强进而影响 ASO 算法性能。

混沌序列随机性和遍历性等特点使得生成的初始解在整个解空间中分布更加均匀, 有利于求解最优问题的全局最优解, 现已被广泛应用于元启发式优化算法的种群初始化中, 故本文也将混沌序列引入 ASO 算法用于初始化原子种群。目前常用的混沌序列生成方法主要有 Logstic 映射和 Tent 映射, 赵欣[19] 的研究已指出 Tent 映射生成的混沌序列具有更好的均匀分布性, 更符合元启发智能算法的初始种群生成, 其序列生成函数为

$$x_{N+1}=\begin{cases}2x_N, & x_N\in[0,0.5]\\ 2(1-x_N), & x_N\in(0.5,1]\end{cases} \tag{17}$$

对式(17)进行伯努利位移变化后, 得

$$x_{N+1}=(2x_N)\bmod 1 \tag{18}$$

式中 N 为原子个数, 初始种群的大小由原子个数 N 和搜索空间维度 D 决定。利用式(18)生成初始种群用以代替 ASO 算法中随机生成的初始种群从而丰富初始种群的多样性, 促使算法寻优结果更接近于全局最优解。

2.2　振幅函数随机参数优化

ASO 在寻觅最优解的过程中, 深度函数 $\eta(t)$ 与拉格朗日乘子 $\lambda(t)$ 作为其中重要的两个参数被用于调整原子自身和原子之间的力相互作用以增强或加快算法全局搜索和局部开发能力, 更有利于求解全局最优解。但 ASO 算法在实际寻优过程中, $\eta(t)$ 与 $\lambda(t)$ 均仅使用非线性递减函数来加快算法收敛速度, 而对算法的全局性探索没有相应策略。

为提高算法的全局探索能力, 本文受简谐振动启发影响引入振幅函数对算法参数 $\eta(t)$ 与 $\lambda(t)$ 进行修正, 利用振幅函数波动跳跃的性质增强算法跳出局部最优的可能。引入的振幅函数 $s(t)$ 定义为

$$s(t)=\text{rand}(|\cos(dt+N)|) \tag{19}$$

式中: N 为原子个数; t 为迭代次数; d 为原子搜索空间维度; rand()为随机函数, 表示在振幅函数生成的数中随机选择一个作为最终作用于参数 $\eta(t)$ 与 $\lambda(t)$ 的波动因子。

根据振幅函数波动性质易知: 当算法中引入振幅因子修正参数时, 参数继承其跳跃波动性, 加强了算法跳出局部最优的可能。但由于引入的振幅因子属于[0,1], 导致搜索步长仅在原有解邻域内进行探索开发, 对整个全局解空间的探索性不够强, 故对式 (19) 进行修正, 得到修正后振幅函数为

$$s(t)=\text{rand}(|\cos(dt+N)|)+1 \tag{20}$$

式 (20) 是由式 (19) 经过平移后得到的, 其不仅保留了振幅函数本身波动性质促使算法跳出局部最优, 而且还加大了算法对解空间的搜索半径, 增强了算法对全局的寻优能力。

经过振幅函数作用后的深度函数 $\eta(t)$ 与拉格朗日乘子 $\lambda(t)$ 可重新定义为

$$\eta(t)=\alpha\left(1-\frac{t-1}{T}\right)^3 e^{-\frac{20ts}{T}} \tag{21}$$

$$\lambda(t)=\beta e^{-\frac{20ts}{T}} \tag{22}$$

式中 s 称为振幅因子, 由式 (20) 计算得出。故第

i个原子在t时刻加速度可被重新定义为

$$a_i^d(t)=-\alpha\left(1-\frac{t-1}{T}\right)^3 \mathrm{e}^{-\frac{20ts}{T}}\frac{(x_i^d(t)-x_j^d(t))}{\left\|x_i(t),x_j(t)\right\|_2}\eta(t)=$$
$$\beta\mathrm{e}^{-\frac{20ts}{T}}\frac{(x_{\mathrm{best}}^d(t)-x_i^d(t))}{m_i^d(t)}+\alpha(1-\frac{t-1}{T})^3\times \quad (23)$$
$$\mathrm{e}^{-\frac{20ts}{T}}\sum_{j\in K_{\mathrm{best}}}\frac{\mathrm{rand}_j[2(h_{ij}(t))^{13}-(h_{ij}(t))^7]}{m_i^d(t)}$$

2.3　步长演变搜索机制

在 ASO 算法中，原子群在解空间中所探索开发得到的最优解为最优原子个体所处的位置，这表明了原子所处位置对 ASO 算法寻优的重要性。在原子质量一定的情况下，原子间相互作用力及原子与最优原子个体间的约束力影响原子运动速度和加速度进而影响原子更新后的位置，最终作用于 ASO 算法本身，致使算法迭代寻优过程变慢，故想加快算法收敛速度需对原子搜索步长也即位置更新公式进行修正。

根据式 (16) 可知，ASO 算法中原子个体位置的更新等于上一次原子自身位置和本次原子运动后的速度之和。而原子运动的一般过程表明：当原子个体逐渐接近于最优原子个体时，由于原子做变速运动，原子位置也随其速度的变化而不断变化。根据原子间相互作用力和约束力作用可知，若想使原子位置快速趋近于最佳原子位置，原子速度应逐渐降低直至为 0，也即是说，原子位置变化应逐渐变慢直至不再发生改变。

因此，为解决 ASO 算法收敛速度慢的问题，本文从原子位置更新过程出发，引入步长演变因子$\omega(t)$对原子位置更新公式进行修正，使原子位置更新过程随算法迭代次数增加而逐渐变慢直至不再变化。$\omega(t)$定义为

$$\omega(t)=\mathrm{e}^{-\frac{d\times t}{T}} \quad (24)$$

式中：t为迭代次数；d为原子搜索空间维度；T为最大迭代次数。由式 (24) 可知，$\omega(t)\in[0,1]$且是一个随着解空间维度和算法迭代次数增加而快速演变的因子。

综上所述，得出新原子位置更新策略为

$$x_i^d(t+1)=\left(x_i^d(t)+v_i^d(t+1)\right)\omega(t) \quad (25)$$

式中：$x_i^d(t)$为第i个原子第t次迭代时位置；$v_i^d(t+1)$为第i个原子第$t+1$次迭代时的速度；$\omega(t)$为模拟原子位置更新过程的步长演变因子。

由于$\omega(t)\in[0,1]$，故式 (25) 的含义为：随着原子个体不断运动逐渐接近于原子最优个体时，其位置动态更新过程随着算法寻优过程逐渐变慢直至其位置与最优原子个体重合，此时得到的原子个体的位置分布即为原子群的最优解。

2.4　IASO 算法的实现

综上所述，IASO 算法求解最优化问题的寻优过程如图 3 所示。

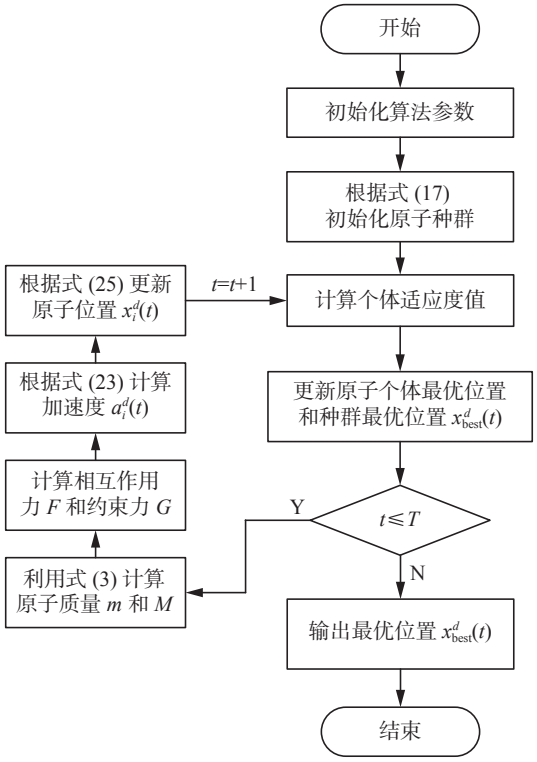

图 3　IASO 算法流程

Fig. 3　Flow chart of the IASO algorithm

3　数值实验与结果分析

为探究和验证 IASO 算法的寻优性能，本文选取 20 个经典基准测试函数，其中设计了 3 组实验，主要包括以下 3 个部分：

1) 30 维度和 100 维度下 IASO 与 4 种元启发式算法的数值实验对比，即选择 10 个经典基准测试函数与 4 种元启发式算法在两个维度下分别进行对比实验并以其数值实验结果对比验证改进算法拥有较好的优化性能。

2) 混合多维度基准测试函数下 IASO 与 4 种元启发式算法的数值实验结果对比，即选择 10 个混合多维度的经典基准测试函数与 4 种元启发式算法进行对比实验并以其数值实验结果对比验证改进算法拥有较好的优化性能。

3) Wilcoxon 秩和检验与算法时间对比，即计算 Wilcoxon 秩和检验 p 值以及统计各对比算法运行时间，通过数值实验结果验证 IASO 比其他算法具有更好的稳定性和优化性。

3.1　实验环境及初始参数设置

1) 实验环境

操作系统 Windows 10，CPU 为 Intel(R) Core

(TM) i7-5557U, 主频 3.10 GHz, 内存为 8 GB, 实验平台为 MATLAB2016a。

2) 实验初始参数设置

为保证实验的客观和公平性,本文将所有对比算法的种群规模统一设置为 50, 最大迭代次数统一设置为 1 000, 其中 ASO 算法和 IASO 算法的参数 $\alpha=50$, $\beta=0.2$; 各实验组均独立进行 100 次数值实验, 并计算 100 次实验结果的均值 (Mean)、标准差 (Std) 及 100 次实验中的最优值 (Best) 作为算法评价指标。

3) 经典基准函数

为验证改进算法具有更高的收敛性和全局性, 本文选取 20 个经典基准函数进行数值实验, 其中 f_1~f_{10}为可变维度基准函数 (每组基准函数的最优值均为 0, 详细描述见表 1); f_{11}~f_{20}为混合多维度的经典基准函数, 具体函数名如下: f_{11}为 Shekel Foxholes1, f_{12}为 Kowalik, f_{13}为 Six-Hump, f_{14}为 Branin, f_{15}为 Goldstin- Price, f_{16}为 Hartman1, f_{17}为 Hartman 2, f_{18}为 shekel Foxholes2, f_{19}为 shekel Foxholes3, f_{20}为 shekel Foxholes4。

表 1　基准测试函数

Table 1　Benchmark function

函数名	表达式	区间	单/多峰	最优值
Sphere	$f_1(x)=\sum_{i=1}^{D}x_i^2$	[−100,100]	单峰	0
Schwefel 2.22	$f_2(x)=\sum_{i=1}^{D}\lvert x_i\rvert+\prod_{i=1}^{D}\lvert x_i\rvert$	[−10,10]	单峰	0
Schwefel 1.2	$f_3(x)=\sum_{i=1}^{D}\left(\sum_{j=1}^{i}x_j\right)^2$	[−100,100]	单峰	0
Step	$f_4(x)=\sum_{i=1}^{D}(x_i+0.5)^2$	[−100,100]	单峰	0
Quartic	$f_5(x)=\sum_{i=1}^{D}ix_i^4+\mathrm{rand}[0,1)$	[−1.28,1.28]	单峰	0
Rastrigin	$f_6(x)=\sum_{i=1}^{D}\left[x_i^2-10\cos(2\pi x_i)+10\right]^2$	[−5.12,5.12]	多峰	0
Ackley	$f_7(x)=-20\exp\left(-0.2\sqrt{\frac{1}{n}\sum_{i=1}^{D}x_i^2}\right)-\exp\left[\frac{1}{n}\sum_{i=1}^{D}\cos(2\pi x_i)\right]+20+\mathrm{e}$	[−32,32]	多峰	0
Griewank	$f_8(x)=\frac{1}{4000}\sum_{i=1}^{D}(x_i-100)^2+\prod_{i=1}^{D}\cos\left(\frac{x_i-100}{\sqrt{i}}\right)+1$	[−600,600]	多峰	0
Levy	$f_9(x)=\sin^2(\pi\omega_i)+\sum_{i=1}^{D}(\omega_i-1)^2\left[1+10\sin^2(\pi\omega_i+1)\right]+(\omega_D-1)^2\left[1+\sin^2(2\pi\omega_d)\right],\quad \omega_i=1+\frac{x_i-1}{4}$	[−10,10]	多峰	0
Weierstrass	$f_{10}(x)=\sum_{i=1}^{D}\left[0.5^i\cos\left(2\pi\,3^i(x_i+0.5)\right)\right]-D\sum_{i=1}^{D}0.5^i\cos\left(2\pi\,3^i\times0.5\right)$	[−0.5,0.5]	多峰	0

3.2　不同算法在 30 维和 100 维下的对比实验

为验证 IASO 算法寻优性能, 以 BOA、MFO、MVO、SSA 和传统 ASO 作为实验对比算法, 分别对 D=30 维和 D=100 维下的 10 个基准测试函数进行仿真对比实验。对比算法参数设置及评价指标以 3.1 节为准, 得到具体实验统计结果见表 2 和表 3。

表 2　6 种算法对 10 个基准函数的统计指标对比结果 (D=30)

Table 2　Comparison of the statistical indexes of ten benchmark functions via six algorithms (D=30)

基准函数	评价指标	BOA	MFO	MVO	SSA	ASO	IASO
f_1	Mean	1.70×10^{-14}	1.60×10^{3}	1.76×10^{-1}	9.46×10^{-9}	2.05×10^{-23}	0.00×10^{0}
	Std	8.04×10^{-16}	3.69×10^{3}	4.90×10^{-2}	1.90×10^{-9}	2.27×10^{-23}	0.00×10^{0}

续表 2

基准函数	评价指标	BOA	MFO	MVO	SSA	ASO	IASO
	Best	1.52×10^{-14}	2.32×10^{-6}	8.34×10^{-2}	4.94×10^{-9}	7.91×10^{-25}	0.00×10^{0}
f_2	Mean	9.72×10^{-12}	3.21×10^{1}	2.87×10^{-1}	4.89×10^{-1}	5.30×10^{-11}	1.54×10^{-184}
	Std	2.13×10^{-12}	1.94×10^{1}	8.36×10^{-2}	6.06×10^{-1}	6.86×10^{-11}	0.00×10^{0}
	Best	3.20×10^{-12}	5.98×10^{-5}	1.67×10^{-1}	6.71×10^{-5}	7.91×10^{-25}	4.88×10^{-188}
f_3	Mean	1.71×10^{-14}	1.48×10^{4}	2.15×10^{1}	4.23×10^{1}	2.02×10^{2}	0.00×10^{0}
	Std	9.37×10^{-16}	1.22×10^{4}	1.01×10^{1}	3.10×10^{1}	1.29×10^{2}	0.00×10^{0}
	Best	1.39×10^{-14}	3.14×10^{2}	6.47×10^{0}	3.93×10^{0}	1.96×10^{1}	0.00×10^{0}
f_4	Mean	0.00×10^{0}	1.20×10^{3}	6.30×10^{0}	9.35×10^{0}	0.00×10^{0}	0.00×10^{0}
	Std	0.00×10^{0}	3.27×10^{3}	3.26×10^{0}	5.48×10^{0}	0.00×10^{0}	0.00×10^{0}
	Best	0.00×10^{0}	0.00×10^{0}	1.00×10^{0}	1.00×10^{0}	0.00×10^{0}	0.00×10^{0}
f_5	Mean	6.12×10^{-4}	2.54×10^{0}	1.45×10^{-2}	5.44×10^{-2}	2.57×10^{-2}	2.34×10^{-5}
	Std	2.55×10^{-4}	5.93×10^{0}	7.14×10^{-3}	2.26×10^{-2}	9.47×10^{-3}	2.17×10^{-5}
	Best	1.38×10^{-4}	2.18×10^{-2}	5.98×10^{-3}	1.41×10^{-2}	8.23×10^{-3}	2.23×10^{-7}
f_6	Mean	3.92×10^{0}	1.45×10^{2}	1.12×10^{2}	4.95×10^{1}	2.86×10^{1}	0.00×10^{0}
	Std	2.76×10^{1}	3.54×10^{1}	2.82×10^{1}	1.50×10^{1}	7.60×10^{0}	0.00×10^{0}
	Best	0.00×10^{0}	7.16×10^{1}	5.48×10^{1}	1.99×10^{1}	1.19×10^{1}	0.00×10^{0}
f_7	Mean	1.13×10^{1}	1.30×10^{1}	6.05×10^{-1}	1.69×10^{0}	3.21×10^{-12}	2.24×10^{-15}
	Std	4.51×10^{1}	8.53×10^{0}	5.73×10^{-1}	9.65×10^{-1}	3.27×10^{-12}	1.73×10^{-15}
	Best	0.00×10^{0}	5.70×10^{-4}	8.47×10^{-2}	2.06×10^{-5}	9.21×10^{-13}	8.88×10^{-16}
f_8	Mean	1.27×10^{-15}	1.27×10^{1}	4.47×10^{-1}	1.10×10^{-2}	1.05×10^{-2}	0.00×10^{0}
	Std	1.39×10^{-15}	3.40×10^{1}	9.99×10^{-2}	1.10×10^{-2}	1.52×10^{-2}	0.00×10^{0}
	Best	0.00×10^{0}	8.06×10^{-6}	1.84×10^{-1}	1.91×10^{-8}	0.00×10^{0}	0.00×10^{0}
f_9	Mean	2.01×10^{0}	2.65×10^{1}	1.60×10^{1}	5.23×10^{0}	2.73×10^{-2}	2.54×10^{0}
	Std	2.42×10^{-1}	9.74×10^{0}	9.61×10^{0}	3.28×10^{0}	1.08×10^{-1}	2.11×10^{-1}
	Best	1.54×10^{0}	3.27×10^{0}	5.52×10^{-1}	8.95×10^{-2}	6.43×10^{-25}	2.04×10^{0}
f_{10}	Mean	1.42×10^{-16}	4.98×10^{0}	9.53×10^{0}	1.12×10^{1}	3.48×10^{-3}	0.00×10^{0}
	Std	1.42×10^{-15}	3.00×10^{0}	2.83×10^{0}	3.28×10^{0}	1.49×10^{-2}	0.00×10^{0}
	Best	0.00×10^{0}	1.25×10^{-2}	4.88×10^{0}	5.54×10^{0}	1.09×10^{-9}	0.00×10^{0}

表 3　6 种算法对 10 个基准函数的统计指标对比结果 (D=100)

Table 3　Comparison of statistical indexes of 10 benchmark functions by six algorithms(D=100)

测试函数	评价指标	BOA	MFO	MVO	SSA	ASO	IASO
f_1	Mean	1.77×10^{-14}	2.72×10^{4}	2.37×10^{1}	8.12×10^{-3}	1.63×10^{-4}	0.00×10^{0}
	Std	9.07×10^{-16}	1.56×10^{4}	3.59×10^{0}	8.85×10^{-3}	7.41×10^{-4}	0.00×10^{0}
	Best	1.55×10^{-14}	1.93×10^{3}	1.69×10^{1}	4.68×10^{-4}	4.26×10^{-17}	0.00×10^{0}
f_2	Mean	$6.02\times10^{+48}$	1.70×10^{2}	$9.21\times10^{+22}$	1.31×10^{1}	2.79×10^{0}	0.00×10^{0}
	Std	$2.87\times10^{+49}$	4.52×10^{1}	$9.00\times10^{+23}$	3.52×10^{0}	2.22×10^{0}	0.00×10^{0}
	Best	$4.90\times10^{+37}$	7.18×10^{1}	2.42×10^{2}	6.60×10^{0}	4.52×10^{-2}	0.00×10^{0}

续表 3

测试函数	评价指标	BOA	MFO	MVO	SSA	ASO	IASO
f_3	Mean	1.77×10^{-14}	1.75×10^{5}	3.14×10^{4}	2.01×10^{4}	3.16×10^{4}	0.00×10^{0}
	Std	1.17×10^{-15}	5.90×10^{4}	4.30×10^{3}	1.03×10^{4}	6.11×10^{3}	0.00×10^{0}
	Best	1.42×10^{-14}	8.40×10^{4}	2.07×10^{4}	6.97×10^{3}	2.08×10^{4}	0.00×10^{0}
f_4	Mean	0.00×10^{0}	2.76×10^{4}	1.46×10^{2}	2.37×10^{2}	3.76×10^{1}	0.00×10^{0}
	Std	0.00×10^{0}	1.28×10^{4}	3.94×10^{1}	7.99×10^{1}	3.44×10^{1}	0.00×10^{0}
	Best	0.00×10^{0}	3.73×10^{3}	6.30×10^{1}	1.11×10^{2}	4.00×10^{0}	0.00×10^{0}
f_5	Mean	5.84×10^{-4}	1.30×10^{2}	2.37×10^{-1}	7.55×10^{-1}	3.53×10^{-1}	2.39×10^{-5}
	Std	2.27×10^{-4}	1.01×10^{2}	5.17×10^{-2}	1.75×10^{-1}	9.39×10^{-2}	2.17×10^{-5}
	Best	1.23×10^{-4}	6.41×10^{0}	1.30×10^{-1}	4.86×10^{-1}	1.80×10^{-1}	5.07×10^{-7}
f_6	Mean	0.00×10^{0}	7.14×10^{2}	6.08×10^{2}	1.35×10^{2}	1.24×10^{2}	0.00×10^{0}
	Std	0.00×10^{0}	7.22×10^{1}	7.21×10^{1}	3.87×10^{1}	1.73×10^{1}	0.00×10^{0}
	Best	0.00×10^{0}	5.86×10^{2}	3.99×10^{2}	5.47×10^{1}	8.86×10^{1}	0.00×10^{0}
f_7	Mean	8.21×10^{-11}	1.99×10^{1}	5.57×10^{0}	5.21×10^{0}	1.33×10^{0}	3.77×10^{-15}
	Std	8.13×10^{-10}	2.28×10^{-1}	5.55×10^{0}	1.02×10^{0}	5.28×10^{-1}	1.40×10^{-15}
	Best	0.00×10^{0}	1.89×10^{1}	2.47×10^{0}	3.20×10^{0}	5.08×10^{-9}	8.88×10^{-16}
f_8	Mean	1.10×10^{-14}	2.68×10^{2}	1.21×10^{0}	1.13×10^{-1}	4.09×10^{-2}	0.00×10^{0}
	Std	5.27×10^{-15}	1.34×10^{2}	3.03×10^{-2}	3.44×10^{-2}	6.21×10^{-2}	0.00×10^{0}
	Best	8.88×10^{-16}	3.97×10^{1}	1.15×10^{0}	5.27×10^{-2}	4.88×10^{-15}	0.00×10^{0}
f_9	Mean	9.10×10^{0}	1.81×10^{2}	1.18×10^{2}	1.70×10^{1}	6.03×10^{0}	9.12×10^{0}
	Std	2.04×10^{-1}	4.71×10^{1}	2.26×10^{1}	6.15×10^{0}	2.93×10^{0}	1.53×10^{-1}
	Best	8.44×10^{0}	1.10×10^{2}	7.10×10^{1}	3.52×10^{0}	9.02×10^{-1}	8.79×10^{0}
f_{10}	Mean	1.14×10^{-15}	5.93×10^{1}	8.22×10^{1}	6.22×10^{1}	1.28×10^{1}	0.00×10^{0}
	Std	5.60×10^{-15}	6.96×10^{0}	7.64×10^{0}	5.48×10^{0}	2.91×10^{0}	0.00×10^{0}
	Best	0.00×10^{0}	4.38×10^{1}	6.54×10^{1}	4.50×10^{1}	6.10×10^{0}	0.00×10^{0}

由表 2 和表 3 可以看出: 与其他元启发算法相比, 本文改进的 ASO 算法 (IASO) 具有较好的寻优性能。

1) 在同等种群规模、迭代次数和相同维度下, 除f_7和f_9函数外, IASO 在其余基准测试函数上的计算精度相较于对比算法均高出数个、数百个数量级甚至达到了最优值, 数值实验结果体现了 IASO 具有更好的计算效果和寻优能力; 虽然在f_7函数上 IASO 的 Best 指标比 BOA 算法差, 但通过对比 Mean 和 Std 两个指标可以发现, IASO 算法的稳定性高于 BOA, 进一步验证了 IASO 算法的可靠性和稳健性; 同时 IASO 无论是在单峰函数 (f_1、f_3和f_4) 还是多峰函数 (f_6、f_8和f_{10}) 上都寻得了 3 个指标的最优计算精度, 显示了 IASO 不仅具有更强的局部开发能力和收敛精度, 而且还拥有更好的全局探索能力。

2) 在相同种群规模、迭代次数, 但不同的维度下, 由表 2 和表 3 对比可知: IASO 在 30 维和 100 维下对 10 个测试函数的寻优结果并无显著差异甚至效果更佳 (f_2), 而其余 5 个对比算法在 100 维度时的寻优能力明显弱于 30 维时的寻优能力, 这表明改进算法在高维度时表现出更好的稳定性和适用性, 说明 IASO 在解决高维度函数时的优越搜索性能。

3) 通过图 4 迭代曲线可知: 无论是在 30 维还是 100 维下, IASO 都显现出更好的寻优能力和稳定性。由迭代曲线图可知, IASO 算法不仅在迭代前期就表现出好的搜索性能, 而且还能让这种优势一直保持到算法迭代终止直到逼近函数的理论最优值。综上所述, 在对可变维度的 10 个

基准测试函数上进行仿真实验时，IASO 在 100 次独立重复实验中表现出更好的收敛精度和局部开发能力且具有更好的全局探索能力和算法稳健性。

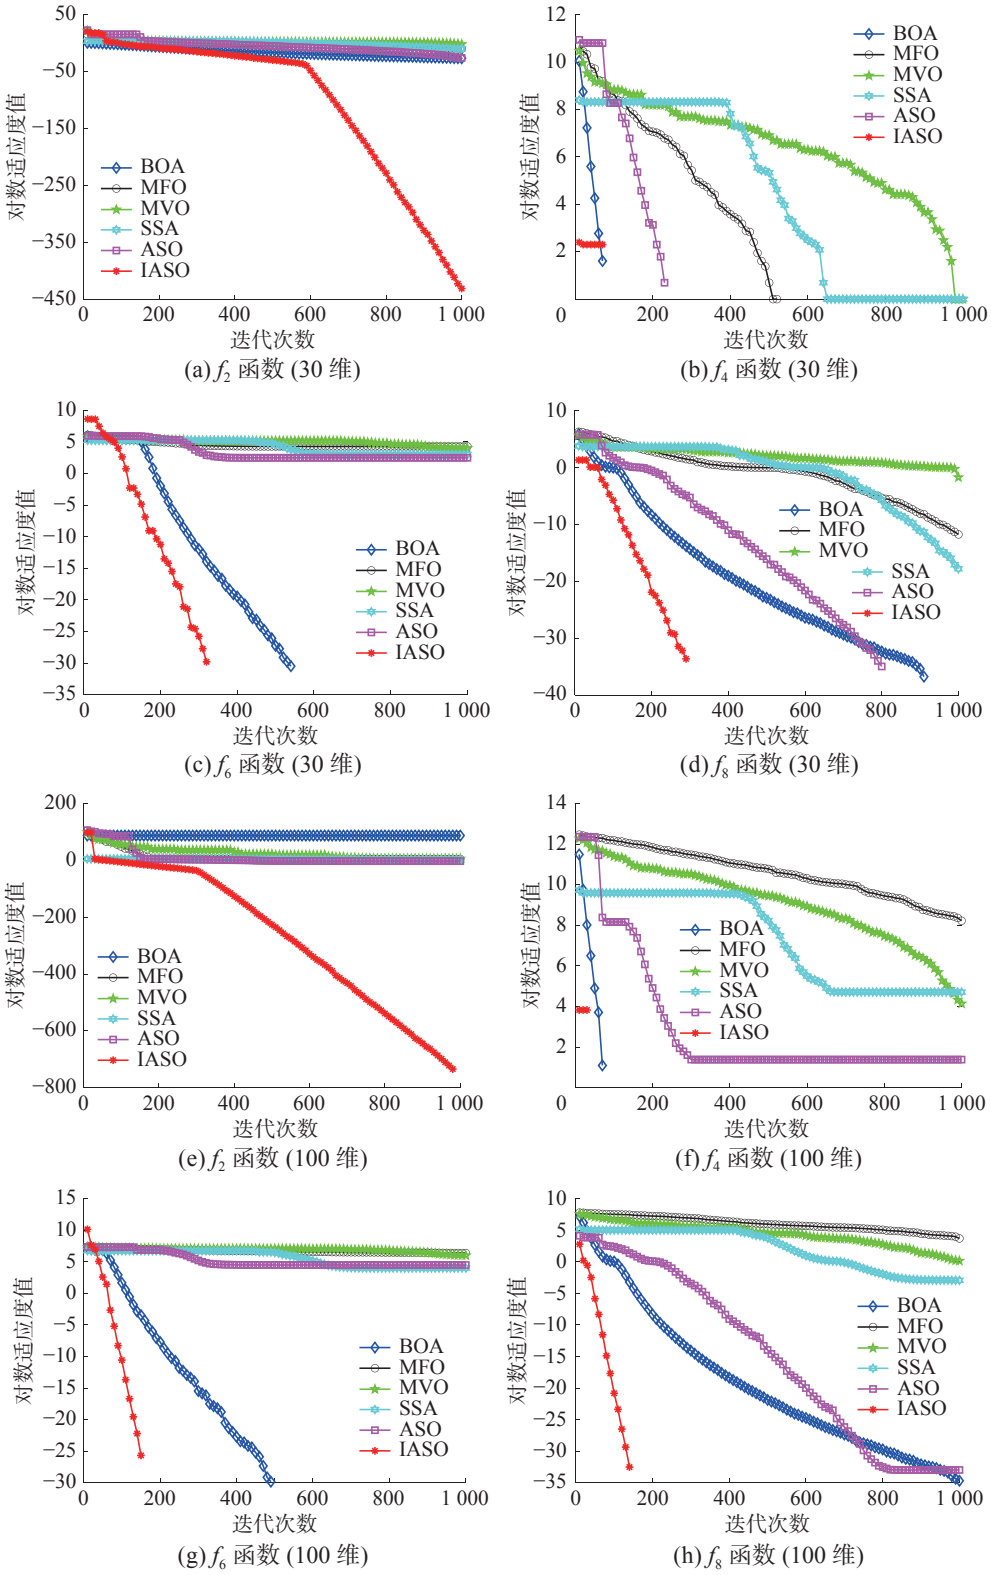

图 4　IASO 与 5 种算法的最佳适应度对数对比曲线

Fig. 4　Logarithmic comparison curve of optimal fitness between IASO and five algorithms

3.3　不同算法在混合多维度函数下的对比实验

为更近一步评估 IASO 有效性和稳定性，以 BOA、MFO、MVO、SSA 和 ASO 作为实验对比算法，对经典的 10 个混合多维度基准测试函数进行仿真对比实验，对比算法参数设置及评价指标以 3.1 节为准，得到具体实验统计结果见表 4。

表 4　6 种算法对 10 个混合多维度基准函数的统计指标对比结果

Table 4　Comparison of statistical indexes of ten mixed multi-dimensional benchmark functions by six algorithms

基准函数	评价指标	BOA	MFO	MVO	SSA	ASO	IASO
f_{11}	Mean	1.00×10^{0}	1.33×10^{0}	9.98×10^{-1}	9.98×10^{-1}	1.03×10^{0}	1.37×10^{0}
	Std	8.01×10^{-3}	1.05×10^{0}	5.79×10^{-12}	1.82×10^{-16}	1.81×10^{-1}	5.11×10^{-1}
	Best	9.98×10^{-1}	9.98×10^{-1}	9.98×10^{-1}	9.98×10^{-1}	9.98×10^{-1}	9.98×10^{-1}
f_{12}	Mean	3.36×10^{-4}	1.09×10^{-3}	4.64×10^{-3}	9.11×10^{-4}	8.42×10^{-4}	4.54×10^{-4}
	Std	2.78×10^{-5}	4.29×10^{-4}	8.00×10^{-3}	2.99×10^{-4}	2.37×10^{-4}	5.83×10^{-5}
	Best	3.09×10^{-4}	5.78×10^{-4}	3.08×10^{-4}	3.58×10^{-4}	6.33×10^{-4}	3.07×10^{-4}
f_{13}	Mean	-1.37×10^{4}	-1.03×10^{0}	-1.03×10^{0}	-1.03×10^{0}	-1.03×10^{0}	-1.03×10^{0}
	Std	1.35×10^{4}	6.78×10^{-16}	4.47×10^{-8}	9.67×10^{-15}	6.65×10^{-16}	1.86×10^{-4}
	Best	-1.28×10^{0}	-1.03×10^{0}	-1.03×10^{0}	-1.03×10^{0}	-1.03×10^{0}	-1.03×10^{0}
f_{14}	Mean	3.99×10^{-1}	3.98×10^{-1}	3.98×10^{-1}	3.98×10^{-1}	3.98×10^{-1}	4.01×10^{-1}
	Std	1.17×10^{-3}	0.00×10^{0}	1.19×10^{-7}	1.63×10^{-14}	0.00×10^{0}	3.59×10^{-3}
	Best	3.98×10^{-1}	3.98×10^{-1}	3.98×10^{-1}	3.98×10^{-1}	3.98×10^{-1}	3.98×10^{-1}
f_{15}	Mean	3.02×10^{0}	3.00×10^{0}	3.00×10^{0}	3.00×10^{0}	3.00×10^{0}	3.02×10^{0}
	Std	2.99×10^{-2}	8.77×10^{-16}	4.72×10^{-7}	4.33×10^{-14}	7.69×10^{-16}	1.92×10^{-2}
	Best	3.00×10^{0}	3.00×10^{0}	3.00×10^{0}	3.00×10^{0}	3.00×10^{0}	3.00×10^{0}
f_{16}	Mean	-6.89×10^{0}	-3.86×10^{0}	-3.86×10^{0}	-3.86×10^{0}	-3.86×10^{0}	-3.86×10^{0}
	Std	6.65×10^{0}	2.71×10^{-15}	1.33×10^{-7}	1.43×10^{-14}	2.71×10^{-15}	4.17×10^{-3}
	Best	-4.00×10^{0}	-3.86×10^{0}	-3.86×10^{0}	-3.86×10^{0}	-3.86×10^{0}	-3.86×10^{0}
f_{17}	Mean	-2.76×10^{0}	-3.22×10^{0}	-3.26×10^{0}	-3.24×10^{0}	-3.32×10^{0}	-3.32×10^{0}
	Std	3.26×10^{-2}	4.99×10^{-2}	6.06×10^{-2}	5.73×10^{-2}	1.34×10^{-15}	8.60×10^{-2}
	Best	-2.56×10^{0}	-3.32×10^{0}	-3.32×10^{0}	-3.32×10^{0}	-3.86×10^{0}	-3.32×10^{0}
f_{18}	Mean	-4.96×10^{0}	-6.73×10^{0}	-8.46×10^{0}	-8.81×10^{0}	-8.89×10^{0}	-4.77×10^{0}
	Std	5.88×10^{-1}	3.38×10^{0}	2.43×10^{0}	2.77×10^{0}	2.36×10^{0}	1.09×10^{0}
	Best	-6.96×10^{0}	-1.02×10^{1}	-1.02×10^{1}	-1.02×10^{1}	-1.02×10^{1}	-9.92×10^{0}
f_{19}	Mean	-5.16×10^{0}	-7.82×10^{0}	-8.58×10^{0}	-9.62×10^{0}	-9.07×10^{0}	-4.62×10^{0}
	Std	1.01×10^{0}	3.50×10^{0}	2.90×10^{0}	2.07×10^{0}	2.48×10^{0}	3.79×10^{-1}
	Best	-8.97×10^{0}	-1.04×10^{1}	-1.04×10^{1}	-1.04×10^{1}	-1.04×10^{1}	-5.92×10^{0}
f_{20}	Mean	-5.18×10^{0}	-9.61×10^{0}	-9.46×10^{0}	-9.21×10^{0}	-9.39×10^{0}	-4.74×10^{0}
	Std	9.63×10^{-1}	2.44×10^{0}	2.19×10^{0}	2.75×10^{0}	2.37×10^{0}	4.53×10^{-1}
	Best	-7.96×10^{0}	-1.05×10^{1}	-1.05×10^{1}	-1.05×10^{1}	-1.05×10^{1}	-6.23×10^{0}

由表 4 可知, IASO 在 f_{11}~f_{17} 上寻优效果显著且在 Best 指标上已经寻得了函数的最优值, 但在 f_{18}、f_{19} 和 f_{20} 上的寻优效果弱于对比算法, 这是由于 IASO 利用非线性快速收敛因子加快原子位置更新方程, 而 f_{18}、f_{19} 和 f_{20} 函数最优值在小范围内波动, 故导致其不能跳出局部最优。

若想增加 IASO 在 f_{18}、f_{19} 和 f_{20} 函数上的寻优精度, 可将快速收敛因子函数值在 1 附近波动, 但此时 IASO 在其余所有测试函数上的寻优精度都会降低, 同时从图 5 的迭代收敛曲线可知: IASO 在求解混合多维函数的迭代过程中显现出更好的寻优能力和更快的迭代速度。因此, 从整体上来说, IASO 相较于其余算法表现出更好的寻优性能。

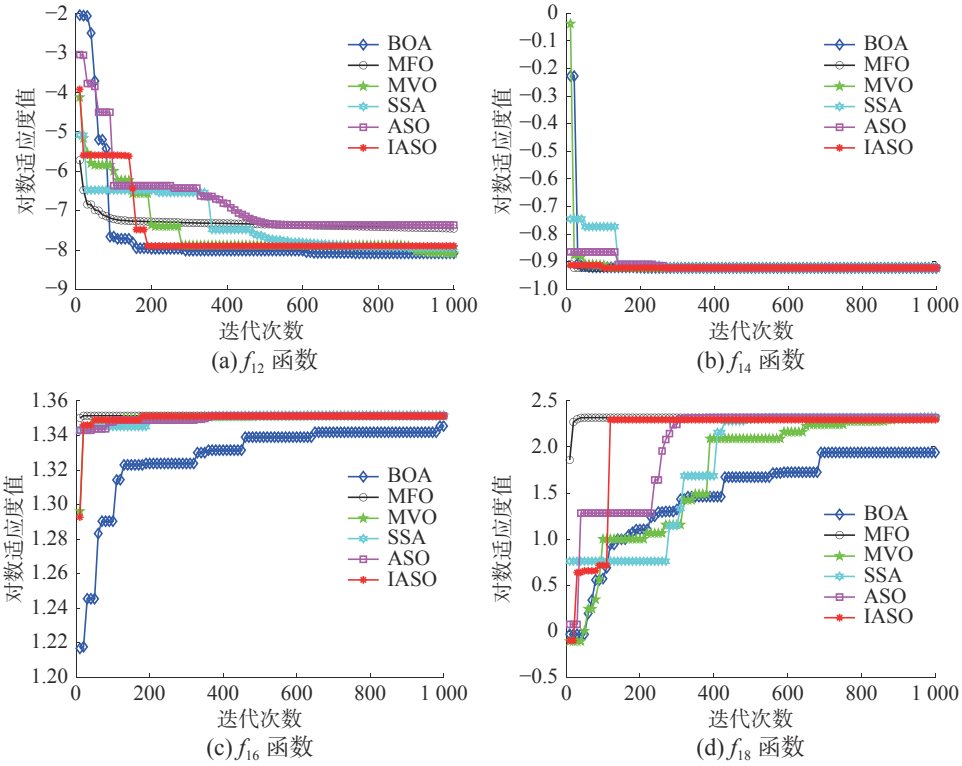

图 5　IASO 与 5 种算法的最佳适应度对数对比曲线

Fig. 5　Logarithmic comparison curve of optimal fitness between IASO and five algorithms

3.4　Wilcoxon 秩和检验

100 次独立重复实验计算所得均值和标准差在整体上衡量了算法优越性，但并不能反馈算法每次运行结果。为更好地评估改进算法的有效性和稳定性，Derrac 等[20]提出算法应该进行统计检验。本文采用 Wilcoxon 秩和检验在 5% 的显著性水平下进行并给出 30 维和 100 维下的 f_2、f_4、f_6、f_8、f_{10}以及混合多维度f_{12}、f_{14}、f_{16}、f_{18}、f_{20}的 IASO 和其他算法的 Wilcoxon 秩和检验中计算的 p 值。例如，若最佳算法是 IASO，则在 IASO vs. ASO、IASO vs. BOA 等之间进行比较。表 5 中 N/A 为“不适用”，表示相应算法可以在秩和检验中无统计数据与自身进行比较；符号“+”、“−”和“=”分别表示 IASO 性能优于、劣于和相当于对比算法；当统计检验值 p<0.05 时被认为是拒绝零假设的有力验证[21]，表 5 中标粗部分表示 p>0.05。

表 5　基准函数的威尔科克森秩和检验 p 值

Table 5　p-value of the Wilcoxon rank-sum test of benchmark functions

测试函数	IASO vs. ASO p-value win	IASO vs. BOA p-value win	IASO vs. MFO p-value win	IASO vs. MVO p-value win	IASO vs. SSA p-value win
f_2(30维)	5.22×10^{-138} +	2.94×10^{-55} +	3.02×10^{-201} +	6.61×10^{-244} +	1.22×10^{-212} +
f_4(30维)	1.71×10^{-25} +	**9.55×10^{-1}** −	5.70×10^{-113} +	N/A =	N/A =
f_6(30维)	3.86×10^{-231} +	7.23×10^{-19} +	4.09×10^{-242} +	3.39×10^{-250}	9.11×10^{-240} +
f_8(30维)	9.71×10^{-104} +	7.98×10^{-108} +	1.51×10^{-275} +	N/A =	1.22×10^{-284} +
f_{10}(30维)	6.59×10^{-135} +	9.06×10^{-11} +	8.68×10^{-168} +	5.19×10^{-209}	1.09×10^{-201} +
f_2(100维)	3.82×10^{-258} +	N/A =	5.62×10^{-292} +	3.26×10^{-294}	2.22×10^{-285} +
f_4(100维)	N/A =	8.42×10^{-4} +	N/A =	N/A =	N/A =
f_6(100维)	4.26×10^{-304} +	5.44×10^{-49} +	3.94×10^{-311} +	2.18×10^{-315}	3.02×10^{-307} +
f_8(100维)	6.84×10^{-254} +	5.75×10^{-236} +	N/A =	N/A =	N/A =
f_{10}(100维)	2.57×10^{-267} +	4.80×10^{-126} +	2.61×10^{-286} +	1.04×10^{-287} +	1.36×10^{-285} +
f_{12}	4.46×10^{-186} +	2.47×10^{-182} +	5.80×10^{-171} +	1.25×10^{-70} +	5.68×10^{-18} +

续表 5

测试函数	IASO vs. ASO *p*-value win	IASO vs. BOA *p*-value win	IASO vs. MFO *p*-value win	IASO vs. MVO *p*-value win	IASO vs. SSA *p*-value win
f_{14}	9.33×10^{-18} +	1.37×10^{-261} +	N/A =	6.06×10^{-90} +	1.27×10^{-4} +
f_{16}	2.42×10^{-36} +	1.25×10^{-227} +	N/A =	2.61×10^{-11} +	6.91×10^{-42} +
f_{18}	2.22×10^{-74} +	2.17×10^{-226} +	N/A =	8.63×10^{-122} +	3.39×10^{-9} +
f_{20}	1.05×10^{-208} +	2.77×10^{-71} +	N/A =	2.79×10^{-101} +	N/A =
+/=/−	14/1/0	13/1/1	9/6/0	11/4/0	11/4/0

由表 5 可知, IASO 仅在 30 维与 f_4 的 IASO vs. BOA 时 p 值大于 0.05, 而在其余所有对比算法的测试函数上的秩和检验结果 p 值都小于 0.05。从整体上来说, IASO 在统计上是显著的, 也即 IASO 相对于对比算法具有更高收敛精度。

3.5　时间对比分析

算法运行时间一定程度上反应了算法时间复杂度大小, 故本文对 6 种不同算法在 20 个基准测试函数上进行了 100 次独立重复实验, 分别记录了 f_1~f_{10} 在 30 维和 100 维下各算法平均运行时间以及 f_{11}~f_{20} 在各算法下的平均运行时间, 图 6 表示 6 个算法在部分基准测试函数上的运行时间柱状图。

图 6(a)、(b) 分别表示 6 种算法在 f_2、f_4、f_6、f_8、f_{10} 在 30 和 100 维下的平均运行时间, 图 6(c) 表示 6 种算法在 f_{12}、f_{14}、f_{16}、f_{18} 及 f_{20} 上的平均运行时间, 图 6(d) 表示 6 种算法在 30 和 100 维下 20 个基准测试函数的平均运行时间之和。由图 6(a)、6(b)、6(c)、6(d) 可知, 在给出的 5 个基准函数中, IASO 在 100 次独立重复实验下的平均运行时间远高于 BOA、MFO、MVO 和 SSA 算法, 这是由于 ASO 自身导致, 而 IASO 平均运行时间略高于 ASO(因为改进算法过程中引入了非线性因子, 导致算法复杂度升高), 但当维度增加时, 相较于其余对比算法 IASO 平均运行时间的增加幅度更小, 这表明 IASO 更适用于求解高维测试函数; 同时, 虽然 IASO 算法平均运行时间略高于 ASO 算法, 但综合其寻优能力 IASO 具有更好寻优性能。

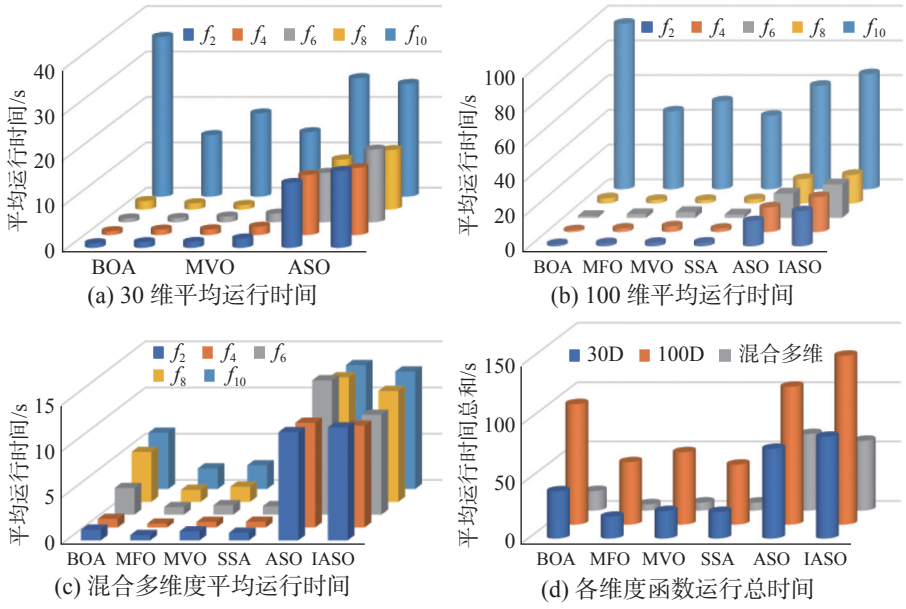

图 6　不同智能优化算法运行时间对比

Fig. 6　Running time comparison of different intelligent optimization algorithms

4　基于 IASO 的 BP 神经网络参数优化方法

通过上述对比实验可知: IASO 在不同基准测试函数和不同维度下的寻优结果相较于其余对比算法具有更好的优越性和更快的收敛性, 故本文将 IASO 求解复杂优化问题时具有的性能优势引入到 BP 神经网络参数优化中, 提出了一种基于 IASO 方法的 BP 神经网络参数优化方法 (IASO-BP), 并将其用于 UCI 数据集分类。

4.1　算法设计步骤

针对分类问题, 本文以 BP 神经网络的分类

准确率最大化为优化原则，将 BP 神经网络的训练过程转化为优化问题寻优过程，利用 IASO 对优化目标进行求解[22]。其基本思想是：通过 IASO 算法优化 BP 神经网络初始权值和阈值，并将 BP 神经网络的训练误差作为个体的适应度值，最后选择最优初始权值和阈值构建 BP 神经网络分类模型。其对应的神经网络分类数学模型为[23-25]

$$Z = \max F(\omega, b)$$
$$\text{s.t.} \begin{cases} \omega \in [\omega_{\min}, \omega_{\max}] \\ b \in [b_{\min}, b_{\max}] \end{cases} \tag{26}$$

式中：Z 为分类精度值；ω 为 BP 神经网络权值；b 为阈值；F 表示选择 BP 神经网络权值和阈值时的分类精度。

设数据集为 Dataset，神经网络输入层节点为 a，隐含层节点为 b，输出层节点为 c，个体维度为 Dim，IASO-BP 具体实现步骤如下：

1）数据预处理及参数初始化。

2）权值与阈值参数编码。利用 BP 神经网络进行初始网络训练得到网络权值和阈值，进行实值编码，得到初始原子种群。

3）计算初始原子种群适应度。将 BP 神经网络的训练误差作为个体适应度值，则适应度函数 $f_i(x)$ 可表示为

$$f_i(x) = \sum_{i=1}^{\text{Dim}} (\hat{y}_i - y_i)^2 \tag{27}$$

式中：Dim 代表个体维度；$\hat{y}_i$ 为网络期望输出值；y_i 为实际输出值。

4）原子种群寻优更新。根据 IASO 算法更新原子种群并采用式 (27) 计算适应度值。

5）判定是否满足终止条件。若满足则输出最优个体 x_i 及最优权值 ω 和阈值 b；反之跳转到 4）继续执行优化。

6）更新 BP 神经网络的权值 ω 和阈值 b 并利用更新后的网络对数据集进行分类。

4.2　仿真实验

为验证 IASO-BP 在进行分类时具有更高的精度，本文采用 UCI 数据集中的 8 个数据集进行数值实验，并将 IASO-BP 与一般 BP 神经网络和 ASO-BP 进行仿真实验，具体实验过程如下。

1) 数据集说明

为验证 IASO-BP 的有效性，本文从 UCI 数据集中选取 8 个数据集进行数值对比实验，包括皮肤科数据集 (Dermatology)、糖尿病数据集 (Diabetes)、肝脏疾病数据集 (Bupa)、玻璃数据集 (Glass)、印度人数据集 (Indian)、植物叶片数据集 (Leaf)、帕金森数据集 (Parkinsons) 及手写数字数据集 (Pendigits)，数据集信息详见表 6。

表 6　UCI 中 8 个数据集物理属性

Table 6　Physical attributes of eight datasets in UCI

数据集	类别数/类	特征数/个	样本数/个	训练集/个	测试集/个
Dermatology	6	33	366	256	110
Diabetes	2	8	768	537	231
Bupa	2	6	345	241	104
Glass	6	9	214	149	65
Indian	2	8	583	408	175
Leaf	12	36	340	237	103
Parkinsons	5	22	529	136	59
Pendigits	10	17	461	7694	3298

2) 实验环境及初始化参数

为保证实验的公平性，本文所采用的仿真环境为：操作系统 Windows 10，CPU 为 Intel(R) Core(TM) i7-5557U，主频 3.10 GHz，内存为 8 GB，实验平台为 MATLAB2016a。针对同一数据集，本文初始参数为：最大迭代次数统一为 20 次，种群数量为 20，权值和阈值边界范围为 [−10,10]，ASO 与 IASO 参数为 $\alpha = 50$，$\beta = 0.2$。分别对 8 个数据集进行 100 次实验并计算 100 次实验结果的均值 (Mean)、标准差 (Std) 及最大值 (Max) 和最小值 (Min) 作为实验最终评价指标，得到实验结果如表 7 所示。

表 7　不同算法分类准确率

Table 7　Classification accuracy of different algorithms　%

数据集	算法	评价指标(分类准确率)			
		Mean	Std	Max	Min
Dermatology	BP	27.46	23.22	78.91	2.73
	ASO-BP	95.51	1.52	98.83	93.75
	IASO-BP	**98.95**	**0.64**	**99.61**	**97.66**
Diabetes	BP	65.61	26.91	97.02	12.10
	ASO-BP	98.31	0.94	**99.63**	96.83
	IASO-BP	**98.86**	**0.45**	**99.63**	**98.14**
Bupa	BP	86.06	17.10	100	45.64
	ASO-BP	98.80	**0.50**	99.59	97.53
	IASO-BP	**99.25**	0.61	**100**	**98.34**
Glass	BP	57.18	31.15	91.28	10.07
	ASO-BP	91.95	2.07	94.63	87.92
	IASO-BP	**96.64**	**1.05**	**98.66**	**95.30**
Indian	BP	73.70	31.02	**100**	8.82
	ASO-BP	97.08	1.04	98.53	95.34
	IASO-BP	**99.75**	**0.26**	**100**	**99.26**
Leaf	BP	9.87	15.48	41.77	0
	ASO-BP	96.33	1.59	98.73	94.51
	IASO-BP	**99.16**	**0.40**	**99.58**	**98.31**

续表 7

数据集	算法	评价指标(分类准确率)			
		Mean	Std	Max	Min
Parkinsons	BP	92.57	6.76	**100**	79.41
	ASO-BP	97.87	1.12	**100**	96.32
	IASO-BP	**98.75**	**1.10**	**100**	**97.06**
Pendigits	BP	18.19	18.92	49.55	0.42
	ASO-BP	99.34	0.40	99.83	98.66
	IASO-BP	**99.97**	**0.03**	**100**	**99.91**

5 结束语

本文针对原子优化算法收敛速度慢、求解精度低和易陷入局部最优等问题, 围绕算法的改进与应用进行了研究, 通过不同数值实验结果对比分析得到以下结论:

1) 提出了一种融合混沌优化并基于振幅随机补偿和步长演变策略模拟原子位置动态演变更新过程的改进 ASO 算法 (IASO), 数值实验结果表明: IASO 相较于 5 种对比算法在求解精度、收敛速度、局部极值逃逸能力和算法稳定性方面均有显著性提高, 通过 Wilcoxon 秩和检验 p 值结果进一步验证了 IASO 的可行性和有效性。

2) 将 IASO 引入 BP 神经网络优化过程中, 设计出一种融合 IASO 和 BP 神经网络的分类模型 (IASO-BP), 并将其用于分类任务, 数值实验结果表明: IASO-BP 能对 BP 神经网络权值和阈值进行有效优化, 优化后网络模型与 BP 神经网络和 ASO-BP 相比显示出更高的分类准确性。

本文所研究工作是对元启发式算法优化神经网络结构参数的一次有益尝试, 数值实验结果充分表明了 IASO 算法和 IASO 算法的可行性和有效性。后续研究将围绕基于 IASO(或其他元启发式算法) 优化其他浅层神经网络参数, 以及搜索最优深度神经网络架构等方面来开展工作。

参考文献:

[1] 董如意. 元启发式优化算法研究与应用 [D]. 长春: 吉林大学, 2019: 1−3.
DONG Ruyi. Research and application of meta-heuristic optimization algorithms[D]. Changchun: Jilin University, 2019: 1−3.

[2] HOLLAND J H. Genetic algorithms[J]. Scientific American, 1992, 267(1): 66–72.

[3] EIBEN A E, BÄCK T. Empirical investigation of multi-parent recombination operators in evolution strategies[J]. Evolutionary computation, 1997, 5(3): 347–365.

[4] MOSCATO P. On evolution, search, optimization, genetic algorithms and martial arts-towards memetic algorithms [J]. Caltech Concurrent Computation Program, 1989.

[5] KENNEDY J, EBERHART R. Particle swarm optimization [C]// Proceedings of ICNN'95-International Conference on Neural Networks. IEEE, 1995: 1942−1948.

[6] ASKARZADEH A. A novel metaheuristic method for solving constrained engineering optimization problems: Crow search algorithm[J]. Computers and structures, 2016, 169: 1–12.

[7] MIRJALILI S, GANDOMI A H, MIRJALILI S Z, et al. Salp swarm algorithm: a bio-inspired optimizer for engineering design problems[J]. Advances in engineering software, 2017, 114: 163–191.

[8] ARORA S, SINGH S. Butterfly optimization algorithm: a novel approach for global optimization[J]. Soft computing, 2019, 23(3): 715–734.

[9] MIRJALILI S. Moth-flame optimization algorithm: a novel nature-inspired heuristic paradigm[J]. Knowledge-based systems, 2015, 89: 228–249.

[10] KIRKPATRICK S, GELATT C D Jr, VECCHI M P. Optimization by simulated annealing[J]. Science, 1983, 220(4598): 671–680.

[11] GONÇALVES M S, LOPEZ R H, MIGUEL L F F. Search group algorithm: a new metaheuristic method for the optimization of truss structures[J]. Computers and structures, 2015, 153: 165–184.

[12] MIRJALILI S, MIRJALILI S M, HATAMLOU A. Multi-verse optimizer: a nature-inspired algorithm for global optimization[J]. Neural computing and applications, 2016, 27(2): 495–513.

[13] ZHAO Weiguo, WANG Liying, ZHANG Zhenxing. A novel atom search optimization for dispersion coefficient estimation in groundwater[J]. Future generation computer systems, 2019, 91: 601–610.

[14] ZHAO Weiguo, WANG Liying, ZHANG Zhenxing. Atom search optimization and its application to solve a hydrogeologic parameter estimation problem[J]. Knowledge-based systems, 2019, 163: 283–304.

[15] ELAZIZ M A, NABIL N, EWEES A A, et al. Automatic data clustering based on hybrid atom search optimization and sine-cosine algorithm[C]//2019 IEEE Congress on Evolutionary Computation. Wellington: IEEE, 2019: 2315−2322.

[16] AGWA A M, EL-FERGANY A A, SARHAN G M. Steady-state modeling of fuel cells based on atom search

optimizer[J]. Energies, 2019, 12(10): 1884.

[17] 柳缔西子, 范勤勤, 胡志华. 基于混沌搜索和权重学习的教与学优化算法及其应用 [J]. 智能系统学报, 2018, 13(5): 818–828.
LIU D, FAN Qinqin, HU Zhihua. Teaching-learning-based optimization algorithm based on chaotic search and weighted learning and its application[J]. CAAI transactions on intelligent systems, 2018, 13(5): 818–828.

[18] 贾鹤鸣, 彭晓旭, 邢致恺, 等. 改进萤火虫优化算法的 Renyi 熵污油图像分割 [J]. 智能系统学报, 2020, 15(2): 367–373.
JIA Heming, PENG Xiaoxu, XING Zhikai, et al. Renyi entropy based on improved firefly optimization algorithm for image segmentation of waste oil[J]. CAAI transactions on intelligent systems, 2020, 15(2): 367–373.

[19] 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 Xin. Research on optimization performance comparison of different one-dimensional chaotic maps[J]. Application research of computers, 2012, 29(3): 913–915.

[20] DERRAC J, GARCÍA S, MOLINA D, et al. A practical tutorial on the use of nonparametric statistical tests as a methodology for comparing evolutionary and swarm intelligence algorithms[J]. Swarm and evolutionary computation, 2011, 1(1): 3–18.

[21] NABIL E. A modified flower pollination algorithm for global optimization[J]. Expert systems with applications, 2016, 57: 192–203.

[22] 刘威, 付杰, 周定宁, 等. 基于改进郊狼优化算法的浅层神经进化方法研究 [J]. 计算机学报, 2021, 44(6): 1200–1213.
LIU Wei, FU Jie, ZHOU Dingning, et al. Research on shallow neural network evolution method based on improved coyote optimization algorithm[J]. Chinese journal of computers, 2021, 44(6): 1200–1213.

[23] 马创, 周代棋, 张业. 基于改进鲸鱼算法的 BP 神经网络水资源需求预测方法 [J]. 计算机科学, 2020, 47(S2): 486–490.
MA Chuang, ZHOU Daiqi, ZHANG Ye. BP neural network water resource demand prediction method based on improved whale algorithm[J]. Computer science, 2020, 47(S2): 486–490.

[24] 马创涛, 邵景峰. 烟花算法改进 BP 神经网络预测模型及其应用 [J]. 控制工程, 2020, 27(8): 1324–1331.
MA Chuangtao, SHAO Jingfeng. Prediction model based on improved BP neural network with fireworks algorithm and its application[J]. Control engineering of China, 2020, 27(8): 1324–1331.

[25] 王振东, 刘尧迪, 胡中栋, 等. 利用改进灰狼算法优化 BP 神经网络的入侵检测 [J]. 小型微型计算机系统, 2021, 42(4): 875–884.
WANG Zhendong, LIU Yaodi, HU Zhongdong, et al. Use improved grey wolf algorithm to optimize BP neural network intrusion detection[J]. Journal of Chinese computer systems, 2021, 42(4): 875–884.

作者简介：

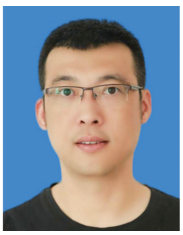

刘威，副教授，博士，中国人工智能学会会员，中国计算机学会会员，主要研究方向为深度神经网络、机器学习、矿业系统工程。

郭直清，硕士研究生，主要研究方向为机器学习与优化算法、数学建模与数据分析。

刘光伟，教授，博士生导师，博士，主要研究方向为露天矿开采设计理论、矿业系统工程。