

# 控制与决策

Control and Decision

## 改进鲸鱼算法及其在浅层神经网络搜索中的权值阈值优化

刘威, 郭直清, 王东, 刘光伟, 姜丰, 牛英杰, 马灵潇

引用本文:

刘威, 郭直清, 王东, 刘光伟, 姜丰, 牛英杰, 马灵潇. 改进鲸鱼算法及其在浅层神经网络搜索中的权值阈值优化[J]. 控制与决策, 2023, 38(4): 1144–1152.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.1713>

---

### 您可能感兴趣的其他文章

#### Articles you may be interested in

##### [一种交互演化改进鲸鱼算法及其收敛性分析](#)

An interactive evolutionary improved whale algorithm and its convergence analysis  
控制与决策. 2023, 38(1): 75–83 <https://doi.org/10.13195/j.kzyjc.2021.0807>

##### [基于深度强化学习的微电网在线优化调度](#)

Online optimal scheduling of a microgrid based on deep reinforcement learning  
控制与决策. 2022, 37(7): 1675–1684 <https://doi.org/10.13195/j.kzyjc.2021.0835>

##### [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>

##### [基于反时限混沌郊狼优化算法的BP神经网络参数优化](#)

Parameter optimization of BP neural network based on coyote optimization algorithm with inverse time chaotic  
控制与决策. 2021, 36(10): 2339–2349 <https://doi.org/10.13195/j.kzyjc.2020.0408>

##### [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>

# 改进鲸鱼算法及其在浅层神经网络搜索中的权值阈值优化

刘威<sup>1,2†</sup>, 郭直清<sup>1,2,3</sup>, 王东<sup>3</sup>, 刘光伟<sup>3</sup>, 姜丰<sup>1</sup>, 牛英杰<sup>1,2</sup>, 马灵潇<sup>1,2</sup>

(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. 辽宁工程技术大学矿业学院, 辽宁阜新 123000)

**摘要:** 为设计出简便高效的方法搜索最优神经网络结构, 提出一种改进鲸鱼优化算法的浅层神经网络搜索方法. 该方法首先通过模拟鲸鱼狩猎的个体偏好行为和鲸鱼群位置移动的非线性权值更新机制对传统鲸鱼优化算法进行改进; 然后将改进鲸鱼优化算法作为浅层 BP 神经网络结构搜索策略, 构建基于浅层 BP 神经网络的最优网络结构的权值阈值搜索优化方法. 数值实验结果表明, 改进的鲸鱼优化算法不仅在求解不同维复杂函数上具有良好的寻优性能, 而且通过改进鲸鱼优化算法搜索得到的最优浅层 BP 神经网络结构在回归任务中具有更好的预测精度和泛化性能.

**关键词:** 神经网络结构搜索; 鲸鱼优化算法; 个体偏好选择; 马尔可夫链; BP 神经网络; 神经进化

**中图分类号:** TP18 **文献标志码:** A

**DOI:** 10.13195/j.kzyjc.2021.1713

**引用格式:** 刘威, 郭直清, 王东, 等. 改进鲸鱼算法及其在浅层神经网络搜索中的权值阈值优化 [J]. 控制与决策, 2023, 38(4): 1144-1152.

## Improved whale optimization algorithm and its weights and thresholds optimization in shallow neural architecture search

LIU Wei<sup>1,2†</sup>, GUO Zhi-qing<sup>1,2,3</sup>, WANG Dong<sup>3</sup>, LIU Guang-wei<sup>3</sup>, JIANG Feng<sup>1</sup>, NIU Ying-jie<sup>1,2</sup>, MA Ling-xiao<sup>1,2</sup>

(1. College of Science, Liaoning Technical University, Fuxin 123000, China; 2. Institute of Intelligent Engineer and Mathematics, Liaoning Technical University, Fuxin 123000, China; 3. College of Mines, Liaoning Technical University, Fuxin 123000, China)

**Abstract:** In order to design a simple and efficient method to search for the optimal neural network architecture, we propose an improved whale optimization algorithm and its shallow neural architecture search's weights and thresholds optimization. This method first improves the traditional whale optimization algorithm by simulating the individual preference behavior of whale hunting and the nonlinear weight update mechanism of whale group position movement; Then, the improved whale optimization algorithm is used as a shallow BP neural network architecture search strategy, and a architecture based on the optimization method of weight threshold search for the optimal network architecture of the shallow BP neural network is constructed. The numerical experimental results show that the improved whale optimization algorithm not only has good optimization performance in solving complex functions with different dimensions, but also the optimal shallow BP neural network architecture searched by the improved whale optimization algorithm has better prediction accuracy and generalization performance in regression tasks.

**Keywords:** neural architecture search; whale optimization algorithm; individual preference choice; Markov chain; BP neural network; neuroevolution

## 0 引言

神经网络结构搜索 (neural architecture search, NAS)<sup>[1]</sup> 是指利用机器替代人类, 对特定任务自动设计性能优异的神经网络结构, 从而探索出特定任务的

最优神经网络模型. 该方法主要由搜索空间、搜索策略和性能评估策略 3 个部分组成, 其中搜索策略对实现最优网络结构的搜索显得十分关键. 但由于神经网络结构搜索中存在大量不可微和多模态离散非

收稿日期: 2021-10-07; 录用日期: 2021-12-30.

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项目 (LNTU20TD-01, LNTU20TD-07).

责任编辑: 曹进德.

†通讯作者. E-mail: lv8218218@126.com.

凸函数,导致传统以梯度下降法为主的搜索策略不再适用,而以进化算法为主的搜索策略却能很好地解决这类问题<sup>[2]</sup>.例如: Vonk 等<sup>[3]</sup>提出的 GPNN、Yao 等<sup>[4]</sup>提出的 EPNet、Stanley 等<sup>[5]</sup>受遗传算法启发提出的 NEAT 及其相应改进 LEAT<sup>[6]</sup>等都在机器学习任务中取得了更好的搜索性能.这表明以进化算法为搜索策略寻找最优神经网络结构模型,从而实现机器学习任务的精准预测已成为可能.

鲸鱼优化算法 (whale optimization algorithm, WOA) 是 Mirjalili 等<sup>[7]</sup>受座头鲸社会行为启发,模拟鲸鱼群狩猎行为的一种元启发式算法.由于其启发机制简单、控制参数少且在解决某些复杂优化问题时具有收敛速度快、全局搜索能力强等特点被广泛应用于工程理论实践中.

为得到更优的神经网络结构,本文提出一种基于个体偏好选择与位置自适应更新机制的改进鲸鱼算法 (improved whale optimization algorithm, IWOA),并将其用于浅层神经网络结构搜索的权值阈值优化 (improved whale optimization algorithm back propagation neural network, IWOABPNN).结果表明:在同等条件下,IWOA 相对于对比算法具有更好的寻优性和收敛性,且经 IWOA 优化得到的神经网络结构在预测时具有更小的均方误差,充分验证了 IWOABPNN 在搜索浅层神经网络结构时的可行性和有效性.

## 1 基于个体偏好和位置自适应更新机制的改进鲸鱼优化算法

### 1.1 概率偏好选择机制

WOA 假定鲸鱼群在选择包围猎物和捕食猎物时概率均为 50%,且算法每次迭代生成的概率  $p$  均为  $[0, 1]$  间均匀分布的随机数,即

$$\vec{X}(t+1) = \begin{cases} \vec{X}_*(t) - \vec{A} \times \vec{D}, & p < 0.5; \\ \vec{D}' \times e^{bl} \times \cos(2\pi l) + \vec{X}_*(t), & p \geq 0.5. \end{cases} \quad (1)$$

其中  $p$  为  $[0, 1]$  间随机数.这与实际自然界中的动物狩猎准则不符,自然界中捕食者发现猎物后,捕食者对猎物抓捕有偏好行为,包围猎物和捕食猎物的概率随时间变化呈现相应变化,故 WOA 中生成的概率  $p$  并不服从均匀分布.针对此,为提高 WOA 的收敛精度和全局探索能力,模拟鲸鱼群捕食猎物偏好行为,设置概率  $p$  生成方式不再服从均匀分布而是随迭代过程变化而变化,即将 WOA 迭代过程分为两个阶段:

1) 迭代前期:模拟并加快鲸鱼群搜索包围猎物过

程.为增大鲸鱼成功捕获猎物概率,IWOA 假定在算法迭代前期鲸鱼群主要执行搜索包围猎物任务,即只执行式(1)中第1个方程并尽可能使此时概率  $p$  小于 0.5,也即当  $p < 0.5$  时,生成的  $p$  尽可能小于 0.5.

2) 迭代后期:模拟并加快鲸鱼群攻击捕获猎物过程.为提高鲸鱼群捕获猎物速度和概率,假设在迭代后期鲸鱼群主要执行攻击并捕获猎物任务,即只执行式(1)中第2个方程并尽可能使此时  $p$  大于等于 0.5,也即当  $p \geq 0.5$  时,生成的  $p$  尽可能大于等于 0.5.

综上所述,给出更新后概率生成公式为

$$p = \begin{cases} \text{randn}(), & 0 < t < t_{\max}/2; \\ \text{rsn}(1, 0.75, 0.5, 0.1), & t \geq t_{\max}/2. \end{cases} \quad (2)$$

其中:  $\text{rsn}(n, \text{location}, \text{scale}, \text{shape})$  为 Azzalini<sup>[8]</sup>提出的偏态分布随机数生成方法,  $t_{\max}$  为算法最大迭代次数.由式(2)可知,生成的概率不在  $[0, 1]$  间,故对其边界进行约束,即

$$p = \begin{cases} 1, & p > 1; \\ 0, & p < 1. \end{cases} \quad (3)$$

图1为1000次迭代下原始参数(无鲸鱼狩猎偏好)与修正后参数(有鲸鱼狩猎偏好)生成的  $p$  值.由图1(b)可知,在迭代前期,据狩猎偏好生成的概率值大多在  $0 \sim 0.5$  间;而在迭代后期,由狩猎偏好生成的概率值大多在  $0.5 \sim 1.0$  间.由此可知,修正后的概率生成策略不仅增大了前期鲸鱼群对猎物包围能力,而且提高了后期鲸鱼群对猎物的捕食能力.

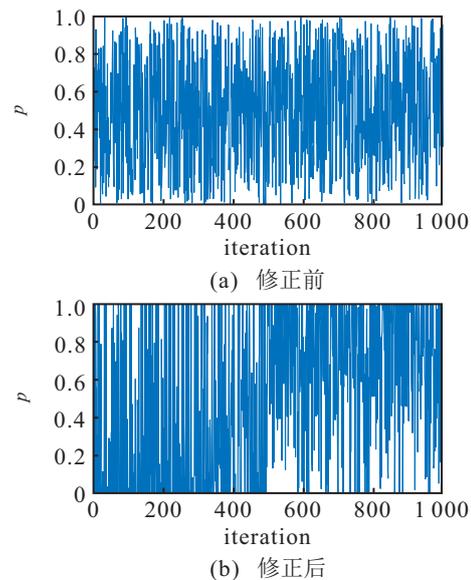


图1 鲸鱼狩猎行为概率生成修正前后对比

### 1.2 参数非线性修正策略

在 WOA 中,  $\vec{A}$  和  $\vec{C}$  是控制鲸鱼群搜索、包围和捕食猎物的重要参数,其中  $\vec{A}$  值由收敛因子  $a$  决定.图2为原始参数  $a$ 、 $\vec{A}$  和  $\vec{C}$  在 1000 次迭代下的变化曲线.

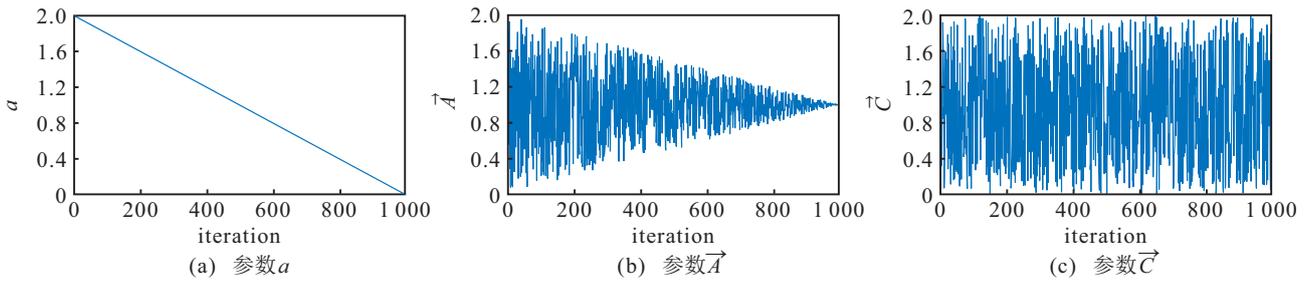


图2 原始参数在1000次迭代下的值

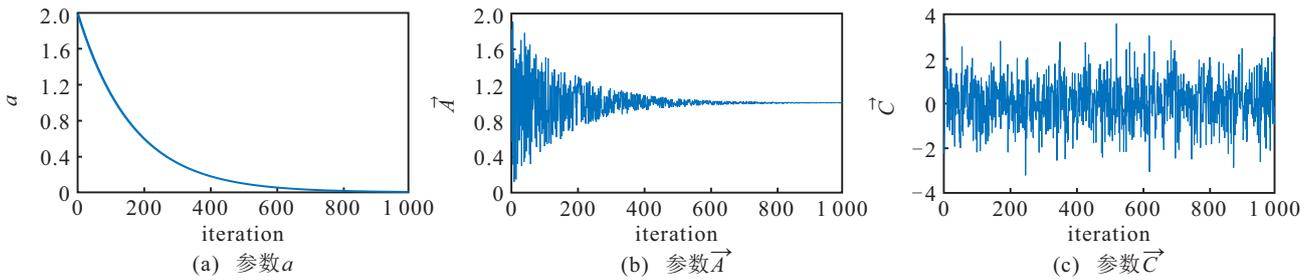


图3 修正后参数在1000次迭代下的值

由图2可知,收敛因子 $a$ 呈线性下降趋势,表明鲸鱼与猎物间距离呈线性递减趋势.参数 $\vec{A}$ 在 $[-2, 2]$ 间且随迭代进行逐渐收敛到0,其模拟了鲸鱼群狩猎过程,即若参数 $\vec{A}$ 的收敛越快,则算法收敛速度也越快.参数 $\vec{C}$ 为0~2间均匀分布的随机数,表明鲸鱼与猎物间距离随机改变,对算法全局勘探和局部开采无明显作用.因此,为提高WOA收敛性能和局部逃逸极值的能力,对参数进行修正.修正后的收敛因子 $a$ 和参数 $\vec{C}$ 为

$$a = 2(e^{-\alpha t} - e^{-\beta t}), \quad (4)$$

$$\vec{C} = 2 \text{randn}(). \quad (5)$$

其中: $a \in [2, 0]$ , $\alpha$ 为控制参数 $a$ 衰减的参数, $\beta$ 为控制参数 $a$ 上升的参数, $t$ 为当前迭代次数, $\text{randn}$ 表示生成一个正态分布随机数.

图3为更新后参数 $a$ 、 $\vec{A}$ 和 $\vec{C}$ 在1000次迭代下的变化曲线.由图2和图3对比可知:1)更新后的收敛因子 $a$ 呈非线性下降趋势且收敛速度更快;2)更新后的参数 $\vec{A}$ 收敛速度明显加快,表明鲸鱼群在狩猎时能更快捕获猎物,即加快了算法收敛速度;3)更新后的参数 $\vec{C}$ 在 $[-4, 4]$ 间随机波动,表明鲸鱼群搜索猎物空间增大,提高了算法跳出局部极值的可能.综上所述,更新后参数相对于原始参数能明显提高WOA的全局勘探和局部开采能力.

### 1.3 权值位置更新策略

为加快鲸鱼群向最优鲸鱼个体移动并快速包围猎物过程,引入非线性扰动因子增强算法全局勘探和局部开发能力,提高算法寻优性能,即

$$\vec{X}_*(t) - \vec{A} \times \vec{D} \times \omega, |\vec{A}| < 1. \quad (6)$$

其中: $\vec{X}_*(t)$ 为当前鲸鱼群体中最优解位置向量, $\vec{A}$ 和 $\vec{C}$ 为系数向量, $a$ 为非线性扰动因子.为对应本文提出的概率偏好选择机制的两个阶段,将 $\omega$ 定义为

$$\omega = 0.8 \times \sin\left(\frac{\pi}{t_{\max}} \times t\right) + 0.3. \quad (7)$$

其中: $\omega \in [0.3, 1.1]$ , $t$ 为当前迭代次数, $t_{\max}$ 为最大迭代次数.由式(6)和(7)可知:在算法迭代搜索过程中,非线性扰动因子 $\omega$ 有两个功能:当 $\omega \in [0.3, 1]$ 时,增大算法跳出局部最优的能力;当 $\omega \in (1, 1.1]$ 时,算法搜索步长增大从而使算法收敛速度加快.

图4为不同扰动因子对算法寻优过程的影响情况.由图4可知,对于常见混沌扰动因子而言,因其混沌性质增强了算法逃逸极值的能力,使得求解全局最优解时的概率更高,同时也使得算法收敛速度减慢.对于所提出的非线性扰动因子 $\omega$ ,其不仅增强了算法逃逸局部极值能力,而且通过增大搜索步长加快了算法收敛速度.因此,相对于混沌扰动因子而言,所提出的非线性扰动因子具有更好的性能.综上所述,算法位置更新公式修正为

$$\vec{X}(t+1) = \begin{cases} \vec{X}_*(t) - \vec{A} \times \vec{D} \times \omega, & p < 0.5; \\ \vec{D}' \times e^{bl} \times \cos(2\pi l) + \vec{X}_*(t), & p \geq 0.5. \end{cases} \quad (8)$$

其中:当 $|\vec{A}| < 1$ 时, $\omega$ 由式(7)计算,当 $|\vec{A}| \geq 1$ 时, $\omega$ 值为1; $\vec{D} = |\vec{C} \times \vec{X}_*(t) - \vec{X}(t)|$ 为最优鲸鱼个体与其他个体间的距离; $p$ 为式(2)与(3)生成的概率.

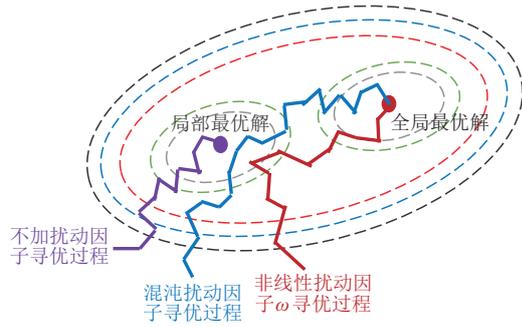


图4 混沌扰动因子与非线性扰动因子的寻优过程

1.4 IWOA算法执行伪码

算法1 IWOA.

input: 鲸鱼种群个数  $N$ , 搜索空间维度  $d$ , 最大迭代次数  $t_{max}$ .

- 1: 初始化鲸鱼种群  $X_i (i = 1, 2, \dots, N)$
  - 2: 计算每个鲸鱼个体的适应度
  - 3:  $X_*$  = 当前最优鲸鱼个体
  - 4: while ( $t < t_{max}$ )
  - 5:   for 1: $N$
  - 6:     由式(4)更新参数  $a, \vec{A}$ , 由式(5)更新参数  $\vec{A}, l$
  - 7:     由式(2)和(3)计算  $p$  值
  - 8:     if 1 ( $p < 0.5$ )
  - 9:       if 2 ( $|\vec{A}| < 1$ )
  - 10:         由式(6)更新当前鲸鱼个体的位置
  - 11:       else if 2 ( $|\vec{A}| \geq 1$ )
  - 12:         选择一个随机个体 ( $X_{rand}$ )
  - 13:         由式(1)更新当前鲸鱼个体的位置
  - 14:       end if 2
  - 15:       else if 1 ( $p \geq 0.5$ )
  - 16:         由式(8)更新当前鲸鱼个体的位置
  - 17:       end if 1
  - 18:     end for
  - 19:   检查并修正边界
  - 20:   计算每个鲸鱼个体的适应度值
  - 21:   如果有更好的鲸鱼个体, 则更新最优鲸鱼个体  $X_*$
  - 22:    $t = t + 1$
  - 23: end while
- output:  $X_*$ .

1.5 收敛性分析

因元启发式算法研究存在过度使用“metaphor”的问题<sup>[9]</sup>, 该研究不应只注重于算法在解决问题时的效果比其他算法“好”, 而更应注重算法本身性质的研究. 为进一步分析 IWOA 算法性能, 结合文献[10-

11] 对其收敛性进行简要分析. 假设鲸鱼状态由狩猎过程中不同鲸鱼所在位置构成, 记为  $\xi$ , 其中  $\xi \in Y, Y$  为可行解空间, 则由鲸鱼所有可能状态构成的状态空间为  $\xi = \{\xi | \xi \in Y\}$ . 鲸鱼群状态由所有鲸鱼状态构成, 记为  $\psi = (\xi_1, \xi_2, \dots, \xi_i)$ , 其中  $i = 1, 2, \dots, N_\psi$  为第  $i$  只鲸鱼状态, 则鲸鱼群所有可能状态构成的鲸鱼状态空间为  $\Omega = \{\psi = (\xi_1, \xi_2, \dots, \xi_i) | \xi_i \in Y (i = 1, 2, \dots, N_\psi)\}$ .

定理1 在 IWOA 算法中, 鲸鱼群状态序列  $\{\psi(t) : t > 0\}$  是有限齐次 Markov 链, 且对应马尔可夫过程为吸收态马尔可夫过程.

证明 1) 有限齐次 Markov 链.

假设在 IWOA 迭代过程中,  $T_\psi(\xi_i) = \xi_j$  为鲸鱼状态由  $\xi_i$  一步转移到  $\xi_j$ , 结合文献[10-11]及马尔可夫状态转移概率性质可知, 在  $\{\psi(t) : t > 0\}$  中, 对于  $\forall \xi(t-1) \in \Omega, \xi(t) \in \Omega$ , 其状态转移概率  $P(T_\psi(\psi(t-1)) = \psi(t))$  由鲸鱼群内所有转移概率  $P(T_\psi(\xi(t-1)) = \xi(t))$  所决定. 同时, 由 IWOA 位置更新方程可知, 鲸鱼群内任一鲸鱼个体状态转移概率  $P(T_\psi(\xi(t-1)) = \xi(t))$  仅与  $t-1$  时刻状态相关, 故转移概率  $P(T_\psi(\psi(t-1)) = \psi(t))$  也仅与  $t-1$  时刻状态相关. 因此, 结合马尔可夫链定义可得鲸鱼群状态序列  $\{\psi(t) : t > 0\}$  具 Markov 性.

因搜索空间均为有限空间, 故  $\xi$  有限; 同时对于一个由  $N_\psi$  个鲸鱼状态构成的鲸鱼群状态空间  $\Omega$  而言, 因  $N_\psi$  为有限正整数, 故鲸鱼群状态空间  $\Omega$  有限; 此外, 鲸鱼群状态空间为可列集, 故  $\{\psi(t) : t > 0\}$  为有限 Markov 链.

由 IWOA 种群更新公式可知, 鲸鱼个体当前状态只与前一时刻鲸鱼个体状态有关, 与鲸鱼当前所处迭代次数无关, 即  $\xi(t)$  只与  $\xi(t-1)$  有关, 与  $t$  无关. 故鲸鱼群状态序列  $\{\psi(t) : t > 0\}$  为有限齐次 Markov 链.

2) 对应马尔可夫过程为吸收态马尔可夫过程.

根据第 1.4 节 IWOA 执行伪码可知, 在 IWOA 寻优过程中, 每次算法找到的当前最优解均会被记录, 即 IWOA 保留了 WOA 算法精英保留策略, 故 IWOA 对应的马尔可夫过程为吸收态马尔可夫过程.

综上所述, 鲸鱼群状态序列  $\{\psi(t) : t > 0\}$  是有限齐次 Markov 链且对应的马尔可夫过程为吸收态马尔可夫过程. □

定理2 IWOA 算法依概率全局收敛.

证明 由文献[11]可知, 当 WOA 螺旋更新和收缩包围机制选择概率相等时, 即使某一鲸鱼个体在螺旋更新阶段陷入局部最优解, 也可以很快地在收

缩包围阶段跳出局部最优. 而IWOA算法虽然对生成概率进行了偏好设置, 但并未改变鲸鱼群在狩猎时的螺旋更新和收缩包围机制的选择概率, 因此, 要证IWOA算法依概率全局收敛, 只需证明IWOA算法的收缩包围机制依概率全局收敛, 即证式(9)依概率全局收敛. 有

$$\vec{X}(t+1) = \vec{X}_*(t) - \vec{A} \times \vec{D} \times \omega, \quad (9)$$

其中  $\omega = 0.8 \times \sin\left(\frac{\pi}{t_{\max}} \times t\right) + 0.3$ .

由无限状态的连续解空间的离散化算法分析理论<sup>[11]</sup>, 假定IWOA算法个体*i*在时刻*t*陷入局部最优状态*L(t)*, 对于式(9)而言, 其离散空间迭代形式为

$$\xi_i(t+1) = L(t) - A \times |C \times L(t) - \xi_i(t)| \times \left(0.8 \times \sin\left(\frac{\pi}{t_{\max}} \times t\right) + 0.3\right), \quad (10)$$

则状态序列  $\{\psi(t) : t > 1\}$  的一步转移概率为

$$\begin{aligned} P\{\xi_i(t+1) = L(t+1) | \xi_i(t) = L(t)\} = \\ P\left\{\xi_i(t+1) = L(t) - A \times |C \times L(t) - L(t)| \times \right. \\ \left. \left(0.8 \times \sin\left(\frac{\pi}{t_{\max}} \times t\right) + 0.3\right) | \xi_i(t) = L(t)\right\} = \\ \begin{cases} 1, L(t) = L(t+1), A = 0 \text{ or } C = 1; \\ 0, L(t) \neq L(t+1), A \neq 0 \text{ and } C \neq 1. \end{cases} \quad (11) \end{aligned}$$

由式(4)和(5)可知, IWOA中给出的参数*A*和*C*在每次迭代过程中仅有加速算法收敛的能力, 但其取值仍是随机的, 故可得出只含有收缩包围机制的IWOA算法很难陷入局部最优. 令*B\**为IWOA算法全局最优解集, 假设只含式(10)的IWOA算法个体*i*在第*t*次迭代时仍未进入全局最优解集*B\**, 则有

$$\begin{aligned} P\{\xi_i(t) \notin B^*\} = \\ P\{\xi_i(t) \notin B^* | \xi_i(t-1) \in B^*\} P\{\xi_i(t-1) \in B^*\} + \\ P\{\xi_i(t) \notin B^* | \xi_i(t-1) \notin B^*\} P\{\xi_i(t-1) \notin B^*\}. \quad (12) \end{aligned}$$

由定理1可知, IWOA为吸收态有限齐次马尔可夫程,  $P\{\xi_i(t) \notin B^* | \xi_i(t-1) \in B^*\} = 0$ , 式(12)变为

$$P\{\xi_i(t) \notin B^*\} = P\{\xi_i(t) \notin B^* | \xi_i(t-1) \notin B^*\} \times P\{\xi_i(t-1) \notin B^*\}. \quad (13)$$

由式(11)可知其不会陷入局部最优状态, 故IWOA在迭代过程中的个体会以一定概率进入全局最优解集并保持下去, 即

$$0 < P\{\xi_i(t) \in B^* | \xi_i(t-1) \notin B^*\} < 1. \quad (14)$$

式(13)可变为

$$P\{\xi_i(t) \notin B^*\} = \{1 - P\{\xi_i(t) \in B^* | \xi_i(t-1) \notin B^*\}\} \times$$

$$P\{\xi_i(t-1) \notin B^*\}. \quad (15)$$

同理可得第*k*次的方程为

$$P\{\xi_i(t) \notin B^* | t\} = \prod_{k=1}^t \{1 - P\{\xi_i(k) \in B^* | \xi_i(k-1) \notin B^*\}\} \times P\{\xi_i(0) \notin B^*\}, \quad (16)$$

$$P\{\xi_i(0) \notin B^*\}, \quad (17)$$

其中  $k = 1, 2, \dots, t$ . 结合式(15), 当迭代次数  $t \rightarrow \infty$  时, 有

$$\lim_{t \rightarrow \infty} \left( \prod_{k=1}^t \{1 - P\{\xi_i(k) \in B^* | \xi_i(k-1) \notin B^*\}\} \right) = 0.$$

即当  $t \rightarrow \infty$  时, 有  $\lim_{t \rightarrow \infty} P\{\xi_i(t) \notin B^*\} = 0$ , 即  $\lim_{t \rightarrow \infty} P\{\xi_i(t) \in B^*\} = 1$ .

综上所述, 当IWOA算法只含有收缩包围机制且迭代次数  $t \rightarrow \infty$  时, IWOA算法依概率收敛于全局最优值. □

## 2 IWOA数值实验

为验证IWOA具有更好的寻优性能, 选取6个基准测试函数在不同维度下与7种元启发式算法寻优结果进行对比分析.

### 2.1 评价指标和基准函数

为保证实验客观公平性, 所有算法最大迭代次数设置为1000; 算法初始种群规模为50; 每组实验均进行30次, 计算其平均值(mean)和标准差(std)作为算法评价指标. 同时选用6个基准函数进行数值实验, 基准函数的详细描述如表1所示.

表1 基准函数

function	name	单/多峰	lb	ub
<i>F</i> <sub>1</sub>	Zakharov	单峰	-100	100
<i>F</i> <sub>2</sub>	Bent Cigar	单峰	-100	100
<i>F</i> <sub>3</sub>	Brown	单峰	-1	4
<i>F</i> <sub>4</sub>	Rastrigin	多峰	-5.12	5.12
<i>F</i> <sub>5</sub>	Expanded Schaffer	多峰	-100	100
<i>F</i> <sub>6</sub>	HGBat	多峰	-100	100

### 2.2 寻优结果分析与对比

表2为EO<sup>[12]</sup>、GWO<sup>[13]</sup>、HHO<sup>[14]</sup>、MFO<sup>[15]</sup>、MVO<sup>[16]</sup>、TSA<sup>[17]</sup>、WOA及IWOA共计8种元启发式算法在30次独立实验下的寻优结果. 图5为两个单峰和两个多峰函数的平均对数适应度收敛曲线. 结合表2和图5可知, 从函数的复杂程度上看, 更小的均值和标准差体现了IWOA相较于其余7种元启发式算法具有更好的收敛精度和寻优稳定性; 从函数寻优的不同维度上看, 当基准函数维度增大时, 其余对比算法的收敛精度均有所下降, 但IWOA的寻优结果仍保持较高的收敛性和寻优性. 综上可知, IWOA相对于对比算法具有更好的收敛性和寻优性.

表2 8种算法对6个基准函数的寻优结果

function	dim	index	EO	GWO	HHO	MFO	MVO	TSA	WOA	IWOA
$F_1$	30	mean	1.77e-90	2.35e-64	7.74e-188	6.19e+03	2.42e-01	9.62e-50	1.24e-02	<b>3.50e-279</b>
		std	8.08e-90	5.13e-64	0.00e+00	1.17e+04	8.54e-02	2.70e-49	6.78e-02	<b>0.00e+00</b>
	100	mean	2.79e-58	7.52e-30	3.80e-180	1.14e+04	4.87e+01	1.06e-25	1.64e+05	<b>1.82e-224</b>
		std	6.55e-58	1.21e-29	0.00e+00	1.72e+04	9.24e+00	1.88e-25	2.20e+04	<b>0.00e+00</b>
$F_2$	30	mean	2.33e-95	1.60e-64	7.96e-185	6.67e+08	1.61e+05	2.46e-46	1.98e-166	<b>0.00e+00</b>
		std	8.38e-95	4.35e-64	0.00e+00	2.54e+09	5.64e+04	4.94e-46	0.00e+00	<b>0.00e+00</b>
	100	mean	5.78e-67	1.52e-28	3.34e-188	6.67e+08	2.09e+07	1.36e-21	2.07e-161	<b>0.00e+00</b>
		std	1.66e-66	1.71e-28	0.00e+00	2.54e+09	3.93e+06	4.34e-21	1.12e-160	<b>0.00e+00</b>
$F_3$	30	mean	5.95e-104	9.23e-73	5.65e-189	9.37e+00	4.15e-04	3.59e-54	1.03e-173	<b>0.00e+00</b>
		std	2.21e-103	1.55e-72	0.00e+00	7.73e+00	1.38e-04	1.56e-53	<b>0.00e+00</b>	<b>0.00e+00</b>
	100	mean	2.49e-75	7.91e-37	1.97e-197	1.01e+01	6.18e-02	8.12e-30	1.23e-171	<b>0.00e+00</b>
		std	3.42e-75	1.52e-36	0.00e+00	7.63e+00	9.24e-03	1.27e-29	<b>0.00e+00</b>	<b>0.00e+00</b>
$F_4$	30	mean	<b>0.00e+00</b>	6.87e-02	<b>0.00e+00</b>	1.42e+02	1.07e+02	1.70e+02	<b>0.00e+00</b>	<b>0.00e+00</b>
		std	<b>0.00e+00</b>	3.76e-01	<b>0.00e+00</b>	4.54e+01	1.84e+01	3.70e+01	<b>0.00e+00</b>	<b>0.00e+00</b>
	100	mean	<b>0.00e+00</b>	1.17e-13	<b>0.00e+00</b>	5.59e+02	6.16e+02	9.30e+02	<b>0.00e+00</b>	<b>0.00e+00</b>
		std	<b>0.00e+00</b>	8.70e-14	<b>0.00e+00</b>	7.81e+01	8.31e+01	1.18e+02	<b>0.00e+00</b>	<b>0.00e+00</b>
$F_5$	30	mean	4.88e+00	5.54e+00	<b>0.00e+00</b>	9.68e+00	1.16e+01	1.20e+01	2.01e+00	<b>0.00e+00</b>
		std	1.52e+00	1.56e+00	<b>0.00e+00</b>	1.46e+00	6.37e-01	5.84e-01	3.35e+00	<b>0.00e+00</b>
	100	mean	2.63e+01	2.72e+01	<b>0.00e+00</b>	9.55e+00	4.42e+01	4.58e+01	4.30e+00	<b>0.00e+00</b>
		std	4.16e+00	6.87e+00	<b>0.00e+00</b>	1.45e+00	1.12e+00	8.96e-01	1.13e+01	<b>0.00e+00</b>
$F_6$	30	mean	4.78e-01	4.50e-01	<b>2.44e-01</b>	1.36e+03	8.11e-01	5.15e-01	3.87e-01	5.00e-01
		std	2.59e-02	5.42e-02	2.46e-01	3.51e+03	4.49e-01	9.84e-02	8.36e-02	<b>2.02e-07</b>
	100	mean	4.94e-01	5.59e-01	<b>4.83e-01</b>	1.02e+03	1.79e+01	5.36e-01	5.33e-01	5.00e-01
		std	8.64e-03	8.11e-02	9.13e-02	3.10e+03	7.17e+00	8.22e-02	1.98e-01	<b>3.47e-08</b>

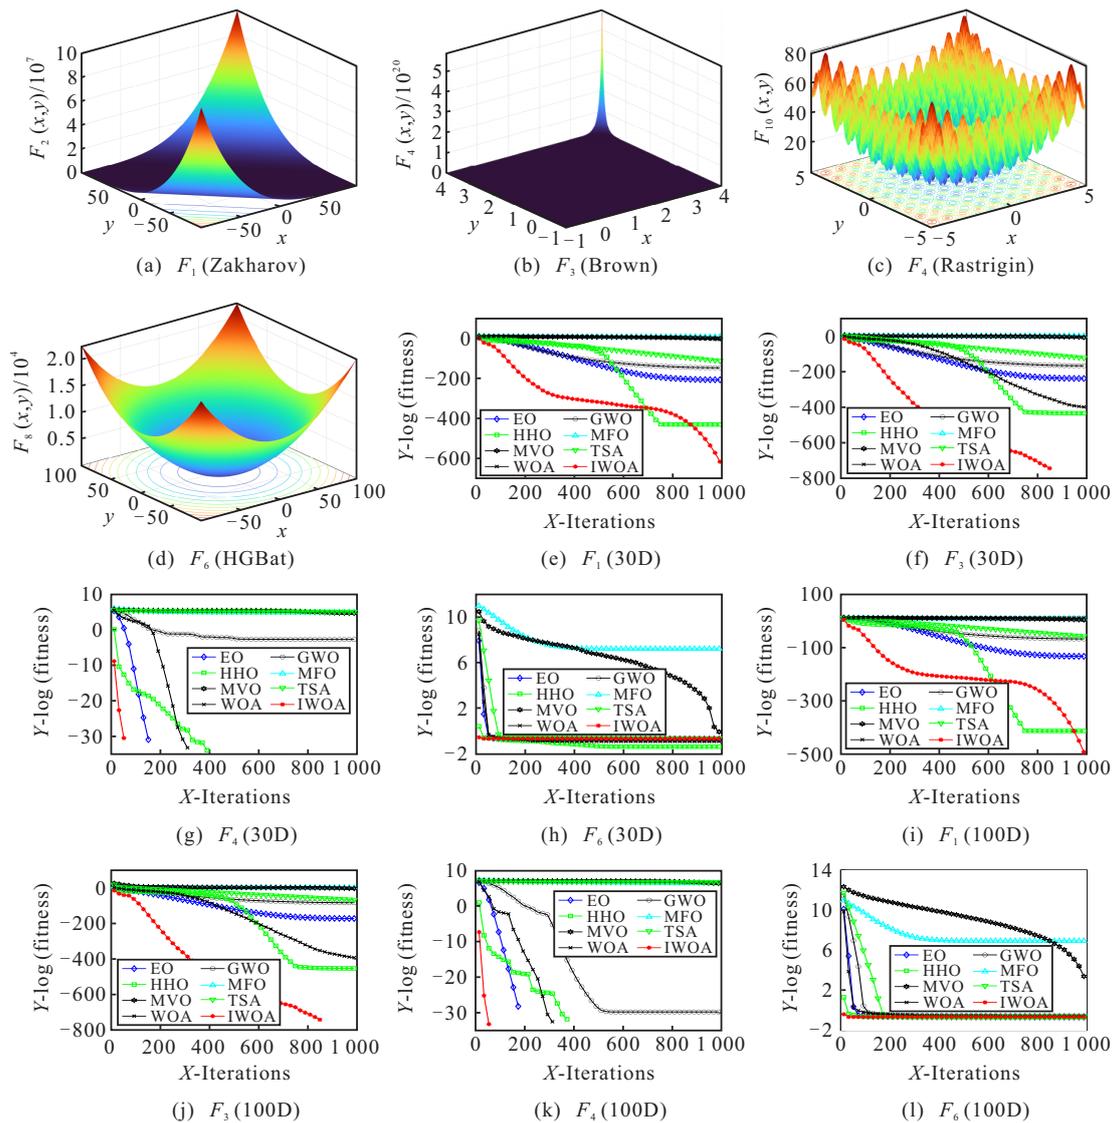


图5 不同维度下的算法平均收敛曲线

### 3 基于IWOA的浅层神经网络搜索方法

传统BP神经网络作为机器学习中最常用的浅层神经网络之一,通过误差反向传播算法和梯度下降法调整网络权值和阈值,从而对网络训练结果和测试结果进行误差修正,直到输出值与理论值一致时完成任务<sup>[18]</sup>.但传统梯度下降法存在收敛精度低且易陷入局部最优的缺点,直接导致BP神经网络模型在预测和分类时出现较大误差的情况.因此,为避免因参数过多带来的梯度爆炸问题,本文将IWOA引入到浅层BP神经网络结构搜索中,提出一种基于IWOA的浅层BP神经网络结构搜索方法(IWOABPNN),具体算法设计思想及实现过程如下.

#### 3.1 算法设计思想

假设神经网络结构为  $\text{Net}\{\Omega, \Phi\}$ . 其中:  $\Omega \in [\omega_{\min}, \omega_{\max}]$ ,  $\Phi \in [\theta_{\min}, \theta_{\max}]$  为权值和阈值空间;  $X \in [x_1, x_2, \dots, x_n]$ ,  $\hat{Y} \in [\hat{y}_1, \hat{y}_2, \dots, \hat{y}_n]$  分别为输入和输

出预测样本空间;待测样本空间为  $Y \in [y_1, y_2, \dots, y_m]$ . 则本文搜索优化目标为

$$\begin{aligned} \min \text{Net} \{ \Omega, \Phi \}; \\ \text{s.t } \Omega \in [\omega_{\min}, \omega_{\max}], \Phi \in [\theta_{\min}, \theta_{\max}]. \end{aligned} \quad (18)$$

当求解得最优网络权值和阈值后,通过计算预测值和实际值的最小均方差衡量每次网络结构优化结果的好坏程度,即

$$Z = \min(\text{MSE}) = \min \left( \frac{1}{m} \sum_{i=1}^m (Y - \hat{Y})^2 \right). \quad (19)$$

假定IWOA中每个鲸鱼个体都对应一个神经网络结构,则最优网络结构的搜索即是对式(17)的优化求解过程.假设初始种群个数为  $N$ ,最大迭代次数为  $t_{\max}$ ,上边界为  $\text{ub}$ ,下边界为  $\text{lb}$ ,神经网络的输入层、隐藏层、输出层的节点个数分别为  $\text{inp}$ 、 $\text{hid}$  和  $\text{out}$ ,则鲸鱼个体维度为  $\text{Dim} = \text{inp} \times \text{hid} + \text{hid} + \text{hid} \times \text{out} + \text{out}$ . 综上,IWOABPNN的主要实现流程如图6所示.

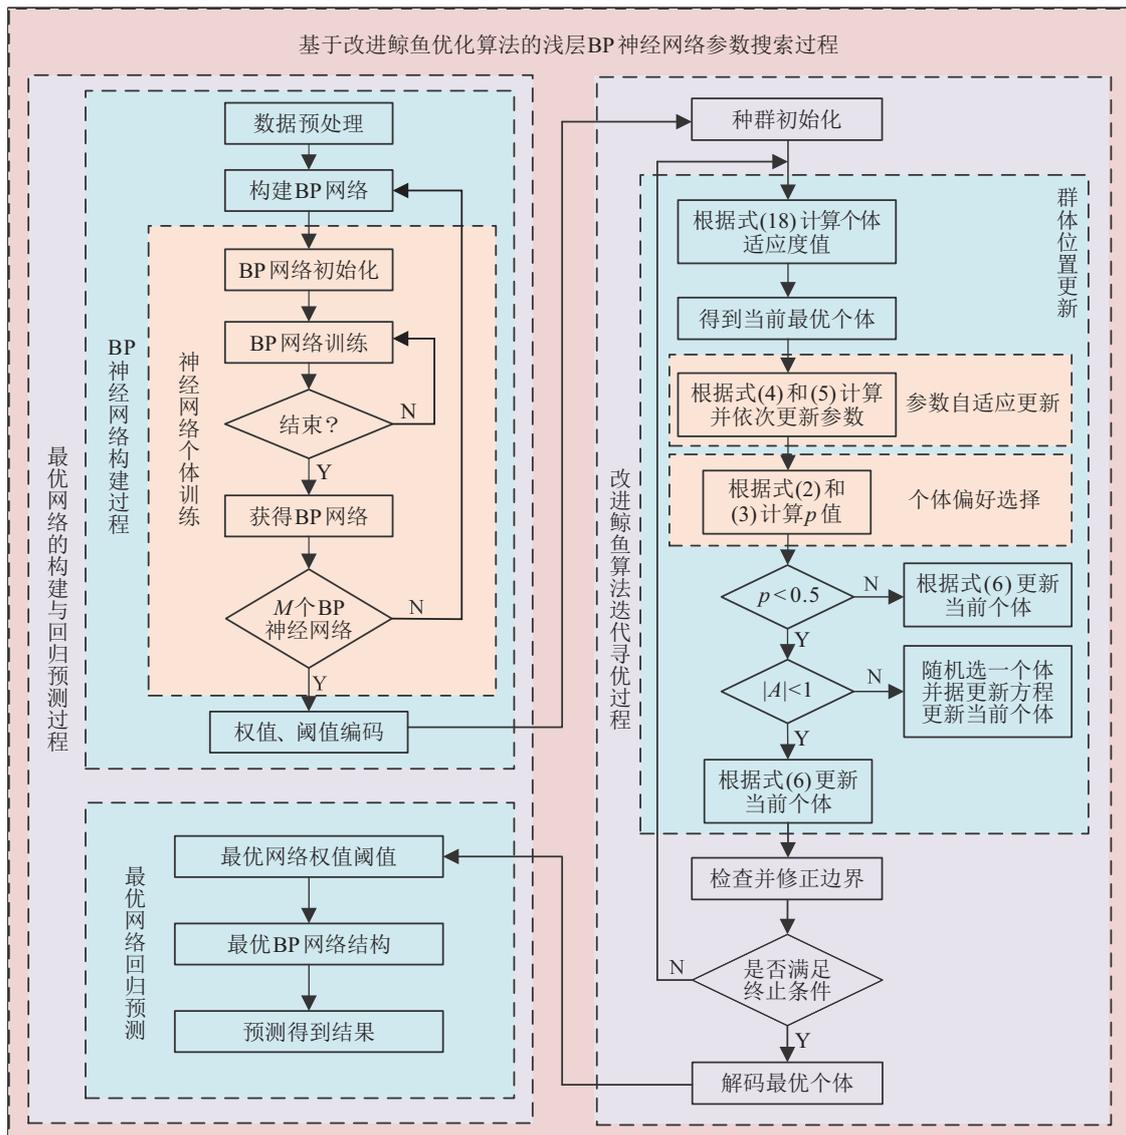


图6 IWOABPNN流程

### 3.2 IWOABPNN 数值实验

为更好地分析 IWOABPNN 具有的泛化性能,选用 UCI<sup>[19]</sup> 中 6 个回归数据集,并将每个数据集按照 80% 训练集和 20% 测试集进行划分,然后利用 3 个不同算法对数据集进行预测分析,以验证基于 IWOA 的浅层神经网络结构搜索方法的有效性.

#### 1) 数据集.

由于采集的回归数据集中存在少量空值及与研究无关的特征指标,对采集数据集进行预处理,处理后的数据集详细说明如表 3 所示.

#### 2) 参数指标设置.

为保证实验的客观公平性,设置算法最大迭代次

表 3 UCI 数据集详细说明

index	datasets	输入变量	输出变量	总样本数
D1	Biascorrection	21	2	7 590
D2	GarmentEmployees	10	1	1 197
D3	Qsaraquatictoxicity	8	1	546
D4	Qsarfishtoxicity	6	1	908
D5	Realestatevaluation	6	1	414
D6	WineQuality	11	1	4 898

数为 50;初始种群规模为 20;将神经网络的权值和阈值上边界设置为 5,下边界为 -5.对每组实验均进行 30 次并记录 30 次实验每个数据集预测结果均方误差 (MSE) 的平均值 (mean)、标准差 (std)、最小值 (best) 和最大值 (worst) 为算法最终评价指标,实验结果如表 4 所示.

表 4 不同算法预测数据集的 MSE 指标结果

datasets	algorithms	mean	std	best	worst	datasets	algorithms	mean	std	best	worst
D1	BPNN	0.026 7	0.003 0	0.022 0	0.032 9	D4	BPNN	0.036 6	0.006 1	0.030 2	0.059 5
	WOABPNN	0.030 7	0.012 8	0.017 6	0.057 8		WOABPNN	0.028 7	0.001 6	0.026 5	0.034 6
	IWOABPNN	<b>0.017 8</b>	<b>0.000 4</b>	<b>0.016 7</b>	<b>0.018 8</b>		IWOABPNN	<b>0.028 3</b>	<b>0.000 9</b>	<b>0.025 9</b>	<b>0.030 8</b>
D2	BPNN	0.173 6	0.062 8	0.114 5	0.348 4	D5	BPNN	0.023 0	0.003 5	0.018 1	0.032 1
	WOABPNN	0.117 2	0.012 7	0.099 2	0.159 1		WOABPNN	0.015 1	0.001 5	0.013 0	0.020 5
	IWOABPNN	<b>0.106 8</b>	<b>0.003 6</b>	<b>0.095 1</b>	<b>0.113 3</b>		IWOABPNN	<b>0.014 7</b>	<b>0.001 1</b>	<b>0.012 7</b>	<b>0.016 6</b>
D3	BPNN	0.078 7	0.010 1	0.066 7	0.118 2	D6	BPNN	0.058 6	0.003 5	0.053 4	0.065 7
	WOABPNN	0.065 3	0.006 2	0.057 3	0.078 9		WOABPNN	0.054 9	0.003 1	0.049 0	0.060 9
	IWOABPNN	<b>0.060 0</b>	<b>0.002 3</b>	<b>0.056 9</b>	<b>0.064 8</b>		IWOABPNN	<b>0.052 5</b>	<b>0.001 4</b>	<b>0.048 5</b>	<b>0.055 6</b>

由表 4 可知,在 30 次的独立实验结果中:无论是从总体指标还是单个指标的结果看,在对 8 个数据集进行回归预测时,更小的 MSE 均值、MSE 最优值和 MSE 最差值表明 IWOABPNN 预测时具有良好的泛化性能;更小的 MSE 标准差也表明 IWOABPNN 具有更好的稳定性和鲁棒性.同时从不同算法的实验结果看,利用 WOA 或 IWOA 搜索最优 BP 神经网络结构比单纯使用 BP 神经网络模型预测效果更好,表明基于元启发式算法搜索神经网络结构对提高神经网络模型性能有着重要意义.

## 4 结 论

本文从探索元启发式算法优化性能和其在浅层神经网络搜索中的权值阈值优化两个方向出发,通过数值仿真实验和理论分析验证了所提出的基于个体偏好选择与位置自适应更新机制改进的鲸鱼优化算法 (IWOA),不仅在求解复杂函数时具有很好的寻优性能,而且将其应用于浅层 BP 神经网络的权值阈值优化中时,表现出更强的鲁棒性和泛化性.后续研究将会从解决元启发式算法过渡使用“metaphor”的问题及提升神经网络架构搜索速度两个角度出发,尝试建立相应的元启发式算法理论分析评估体系及社区交流模块,以便于更好地促进新型元启发式算法在优化领域或其他研究领域的应用.

## 参考文献 (References)

- [1] 孟子尧,谷雪,梁艳春,等.深度神经架构搜索综述[J].计算机研究与发展,2021,58(1):22-33.  
(Meng Z Y, Gu X, Liang Y C, et al. Deep neural architecture search: A survey[J]. Journal of Computer Research and Development, 2021, 58(1): 22-33.)
- [2] Salimans T, Ho J, Chen X, et al. Evolution strategies as a scalable alternative to reinforcement learning[J/OL]. 2017, arXiv: 1703.03864.
- [3] Vonk E, Jain L C, Veelenturf L P J, et al. Automatic generation of a neural network architecture using evolutionary computation[C]. Proceedings Electronic Technology Directions to the Year. Adelaide, 1995: 144-149.
- [4] Yao X, Liu Y. A new evolutionary system for evolving artificial neural networks[J]. IEEE Transactions on Neural Networks, 1997, 8(3): 694-713.
- [5] Stanley K O, Miikkulainen R. Evolving neural networks through augmenting topologies[J]. Evolutionary Computation, 2002, 10(2): 99-127.
- [6] Liang J, Meyerson E, Hodjat B, et al. Evolutionary neural AutoML for deep learning[C]. Proceedings of the Genetic and Evolutionary Computation Conference. Piscataway: IEEE, 2019: 401-409.
- [7] Mirjalili S, Lewis A. The whale optimization algorithm[J]. Advances in Engineering Software, 2016, 95: 51-67.
- [8] Azzalini A. The skew-normal and related families[M].

- Cambridge: Cambridge University Press, 2013.
- [9] Sörensen K. Metaheuristics-the metaphor exposed[J]. International Transactions in Operational Research, 2015, 22(1): 3-18.
- [10] 宁爱平, 张雪英. 人工蜂群算法的收敛性分析[J]. 控制与决策, 2013, 28(10): 1554-1558.  
(Ning A P, Zhang X Y. Convergence analysis of artificial bee colony algorithm[J]. Control and Decision, 2013, 28(10): 1554-1558.)
- [11] 冯文涛, 邓兵. 鲸鱼优化算法的全局收敛性分析及参数选择研究[J]. 控制理论与应用, 2021, 38(5): 641-651.  
(Feng W T, Deng B. Global convergence analysis and research on parameter selection of whale optimization algorithm[J]. Control Theory & Applications, 2021, 38(5): 641-651.)
- [12] Faramarzi A, Heidarinejad M, Stephens B, et al. Equilibrium optimizer: A novel optimization algorithm[J]. Knowledge-Based Systems, 2020, 191: 105190.
- [13] Mirjalili S, Mirjalili S M, Lewis A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61.
- [14] Heidari A A, Mirjalili S, Faris H, et al. Harris Hawks optimization: Algorithm and applications[J]. Future Generation Computer Systems, 2019, 97: 849-872.
- [15] Mirjalili S. Moth-flame optimization algorithm: A novel nature-inspired heuristic paradigm[J]. Knowledge-Based Systems, 2015, 89: 228-249.
- [16] 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.
- [17] Kaur S, Awasthi L K, Sangal A L, et al. Tunicate swarm algorithm: A new bio-inspired based metaheuristic paradigm for global optimization[J]. Engineering Applications of Artificial Intelligence, 2020, 90: 103541.
- [18] 刘威, 刘尚, 白润才, 等. 互学习神经网络训练方法研究[J]. 计算机学报, 2017, 40(6): 1291-1308.  
(Liu W, Liu S, Bai R C, et al. Research of mutual learning neural network training method[J]. Chinese Journal of Computers, 2017, 40(6): 1291-1308.)
- [19] Frank A. Uci machine learning repository[DB/OL]. (2021-08-25). <http://archive.ics.uci.edu/ml>.

### 作者简介

刘威(1977—), 男, 副教授, 博士, 从事深度神经网络、机器学习、矿业系统工程等研究, E-mail: lv8218218@126.com;

郭直清(1997—), 男, 硕士生, 从事机器学习与优化算法、数学建模与数据分析、智能调度的研究, E-mail: gzq142857@126.com;

王东(1978—), 男, 教授, 博士生导师, 从事露天矿开采设计理论、矿业系统工程等研究, E-mail: Intu\_wd@163.com;

刘光伟(1981—), 男, 教授, 博士生导师, 从事露天矿开采设计理论、矿业系统工程等研究, E-mail: liu\_guangwei@yeah.net;

姜丰(1999—), 女, 本科生, 从事数学与应用数学的研究, E-mail: qf11120809@163.com;

牛英杰(1998—), 男, 硕士生, 从事机器学习与智能优化算法的研究, E-mail: 1805776973@qq.com;

马灵潇(1998—), 女, 硕士生, 从事机器学习与智能优化算法的研究, E-mail: 2806617295@qq.com.

(责任编辑: 郑晓蕾)

## 下 期 要 目

- 基于博弈论的多车智能驾驶交互决策综述 . . . . . 衣 鹏, 等
- 天空地一体化网络环境下多运动体系统跨域协同控制与智能决策综述 . . . . . 夏元清, 等
- 强化学习与自适应动态规划: 从基础理论到多智能体系统中的应用进展综述 . . . . . 温广辉, 等
- 基于轻量化深度学习网络的工业环境小目标缺陷检测 . . . . . 叶卓勋, 等
- 带有执行器故障的多水面船固定时间分布式滑模协同控制 . . . . . 夏国清, 等
- 输出死区下的随机多智能体系统一致性饱和控制 . . . . . 于跃飞, 等
- 基于事件触发和状态翻转的布尔控制网络输出跟踪 . . . . . 徐 勇, 等
- 部分可观测下基于 RGMAAC 算法的多智能体协同 . . . . . 王子豪, 等
- 基于事件触发的非线性多智能体系统的固定时间分群一致性 . . . . . 吴新杰, 等
- 欠驱动无人船非奇异固定时间鲁棒包容控制 . . . . . 马俊达, 等