

# 基于Q学习的自适应行为选择鸚鵡优化算法

## ——QLAB-PO算法

章洛铭

温州大学计算机与人工智能学院, 浙江 温州

收稿日期: 2026年2月28日; 录用日期: 2026年3月27日; 发布日期: 2026年4月7日

### 摘要

针对传统鸚鵡优化算法(Parrot Optimizer, PO)在复杂优化问题中行为选择单一、收敛速度慢、易陷入局部最优等问题, 本文提出一种基于Q学习的自适应行为选择鸚鵡优化算法(Q-Learning Based Adaptive Behavior Selection Parrot Optimizer, QLAB-PO)。该算法通过把强化学习中的Q学习机制引入鸚鵡优化算法中, 借助选择Q表, 使算法能够根据当前搜索情况自适应地选择相应策略。算法在原有四种行为模式的基础上添加了群体学习行为和自适应变异行为, 并通过Q学习动态调整所选择策略。实验结果表明, QLAB-PO算法在CEC2017标准测试函数上的收敛速度和求解精度均显著优于原始PO算法及其他主流元启发式算法, 验证了所提算法的有效性和优越性。

### 关键词

鸚鵡优化算法, Q学习, 自适应行为选择

# Q-Learning Based Adaptive Behavior Selection Parrot Optimizer

## ——QLAB-PO Algorithm

Luoming Zhang

Department of Computer Science and Artificial Intelligence, Wenzhou University, Wenzhou Zhejiang

Received: February 28, 2026; accepted: March 27, 2026; published: April 7, 2026

### Abstract

To address the problems of traditional Parrot Optimizer (PO) algorithms, such as limited behavior

selection, slow convergence speed, and susceptibility to local optima in complex optimization problems, this paper proposes a Q-Learning Based Adaptive Behavior Selection Parrot Optimizer (QLAB-PO). This algorithm introduces the Q-learning mechanism from reinforcement learning into the Parrot Optimizer, constructing a Q-table of behavior selections to adaptively select appropriate strategies based on the current search situation. In addition to the original four behavior modes, the algorithm adds swarm learning and adaptive mutation behaviors, and dynamically adjusts the selected strategies through Q-learning. Experimental results show that the QLAB-PO algorithm significantly outperforms the original PO algorithm and other mainstream metaheuristic algorithms in terms of convergence speed and solution accuracy on the CEC2017 standard test function, validating the effectiveness and superiority of the proposed algorithm.

## Keywords

Parrot Optimizer, Q-Learning, Adaptive Behavior Selection

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

优化问题广泛存在于科学研究和工程实践的各个领域，如生产调度、路径规划、特征选择等。随着问题维度的增大以及复杂度的提升，传统优化方法往往难以在较短时间内获得较为满意的解。元启发式算法作为一种具有全局搜索能力的随机优化方法，因其不依赖问题的具体数学特性、实现简单、适用范围广等优点，受到了学术界和工业界的广泛关注[1]。

近年来，受自然界生物行为启发的群体智能优化算法蓬勃发展。粒子群优化算法(Particle Swarm Optimization, PSO)模拟鸟群觅食行为[2]，灰狼优化算法(Grey Wolf Optimizer, GWO)模拟灰狼的社会等级和狩猎机制[3]，鲸鱼优化算法(Whale Optimization Algorithm, WOA)模拟座头鲸的泡泡网捕食行为[4]。2024年，Zhang 等人提出了鸚鵡优化算法(Parrot Optimizer, PO) [5]，该算法模拟鸚鵡的4种自然行为(觅食、停留、交流、恐惧陌生者)进行优化搜索，在多个测试函数上展现了良好的性能。

然而，原始 PO 算法存在一些不足：首先，算法的随机选择行为模式，缺乏对搜索状态的感知和适应性调整能力；同时，行为选择策略固定，无法根据问题的特性和搜索阶段进行动态调整；最后，算法容易陷入局部最优，特别是在处理多峰的复杂优化问题时表现往往不佳。

强化学习(Reinforcement Learning, RL)是一种通过与环境交互来学习最优策略的机器学习方法其中的 Q 学习(Q-Learning)属于强化学习的经典方法之一，通过维护一个 Q 值表来评估在不同状态下采取不同动作的期望回报，从而实现最优决策[6]。并且，将 Q 学习机制引入元启发式算法，可以使算法具备自适应行为选择能力，根据搜索反馈动态调整策略，提高算法的收敛性能[7]。如李等将 Q 学习与鲸鱼优化算法相结合提出(PWOQLA) [8]，也有国外学者将 Q 学习与粒子群优化算法相结合应用于机器人路径规划[9]。

基于上述分析，本文提出一种基于 Q 学习的自适应行为选择鸚鵡优化算法(Q-Learning Based Adaptive Behavior Selection Parrot Optimizer, QLAB-PO)。主要贡献包括：(1) 增加了 2 种行为模式，丰富了算法的搜索策略；(2) 引入 Q 学习机制，构建行为选择 Q 表，实现自适应行为决策；(3) 设计了动态贪婪策略和 Q 表重置机制，平衡探索与开发；(4) 在 CEC2017 的 30 个标准测试函数[10]上验证了算法的有效性。

## 2. 相关工作

### 2.1. 鸚鵡优化算法

鸚鵡优化算法(PO)是 Zhang 等人于 2024 年提出的一种新型元启发式算法。该算法模拟了鸚鵡的 4 种自然行为:

(1) 觅食行为(Foraging Behavior): 模拟鸚鵡在食物源附近搜索食物的行为, 利用 Levy 飞行策略进行全局探索;

$$X_i = (X_i - X_{best}) \cdot Levy(dim) + rand \cdot mean(X_i) \cdot (1 - t/T)^{\{2t/T\}} \quad (1)$$

(2) 停留行为(Staying Behavior): 模拟鸚鵡停留在栖息地休息的行为, 在当前位置附近进行局部搜索;

$$X_i = X_i - X_{best} \cdot Levy(dim) + randn \cdot (1 - t/T) \cdot ones(1, dim) \quad (2)$$

(3) 交流行为(Communicating Behavior): 模拟鸚鵡之间的信息交流, 通过群体协作提高搜索效率;

$$X_i = X_i + \alpha \cdot (1 - t/T) \cdot [X_i - mean(X)] \quad (3)$$

(4) 恐惧陌生者行为(Fear of Strangers Behavior): 模拟鸚鵡对陌生威胁的逃避反应, 增强算法逃离局部最优的能力;

$$X_i = X_i + rand \cdot \cos(\pi t/2T) \cdot (X_{best} - X_i) - \cos(\theta) \cdot (t/T)^{2/T} \cdot (X_i - X_{best}) \quad (4)$$

### 2.2. Q 学习算法

Q 学习是一种无模型的强化学习算法。算法通过维护一个 Q 值表  $Q(s, a)$  来评估在状态  $s$  下采取动作  $a$  的期望累积回报。通过采用贝尔曼最优方程(Bellman Optimality Equation), 利用当前估计来更新对未来的预测。算法无需预先知道环境的转移概率和奖励函数, 仅通过与环境的交互经验即可学习最优策略。Q 值的更新公式为:

$$Q(s_t, a_t) = Q(s_t, a_t) + \alpha [r_{t+1} + \gamma \max_a Q(s_{t+1}, a) - Q(s_t, a_t)] \quad (5)$$

其中,  $\alpha$  为学习率,  $\gamma$  为折扣因子,  $r_{t+1}$  为即时奖励。Q 学习通过不断迭代更新 Q 值表, 最终收敛到最优策略。

## 3. 提出的 QLAB-PO 算法

QLAB-PO 算法的核心思想是将 Q 学习机制融入鸚鵡优化算法中, 通过构建行为选择 Q 表, 使算法能够根据当前搜索状态自适应地选择相应行为策略。算法框架如图 1 所示。

### 3.1. 算法框架

QLAB-PO 算法的核心思想是将 Q 学习机制融入鸚鵡优化过程, 通过构建行为选择 Q 表, 使算法能够根据当前搜索状态自适应地选择最优行为策略。算法框架如图 1 所示, 主要包括以下步骤:

- (1) 初始化: 随机生成初始种群, 初始化 Q 表;
- (2) 状态评估: 根据当前解的质量评估个体状态;
- (3) 行为选择: 基于  $\epsilon$ -贪婪策略选择行为;
- (4) 行为执行: 根据选择的行为更新个体位置;
- (5) Q 表更新: 根据执行结果更新 Q 值;
- (6) 终止判断: 若满足终止条件则输出最优解, 否则返回步骤(2)。

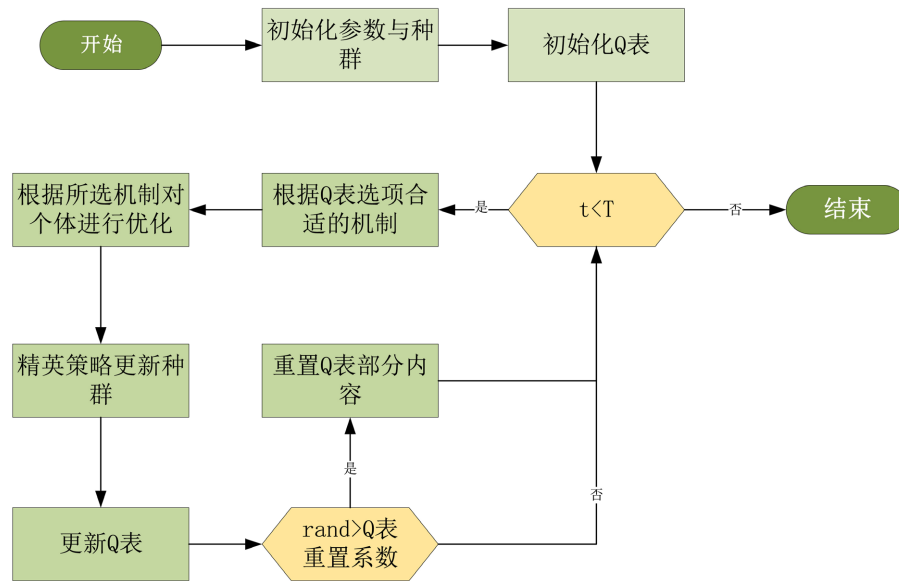


Figure 1. The flowchart of QLAB-PO  
图 1. QLAB-PO 流程图

### 3.2. 行为模式设计

除了 2.1 节中提到的 4 种行为外，本文新加了以下两种行为：

群体学习行为：借鉴人工蜂群算法的思想，通过向优秀个体学习来改进当前解。算法随机选择两个不同的邻居个体，利用 GQI (Global Quality Improvement) 策略[11]更新位置。

自适应变异行为引入差分进化的思想[12]，根据个体适应度自适应地选择变异概率：

$$p_{mutate} = 0.95 \cdot (f(X_i) - f_{best}) / (f_{worst} - f_{best}) + 0.05 \quad (6)$$

### 3.3. Q 学习机制

QLAB-PO 算法将每个个体的适应度等级作为状态，将六种行为模式作为可选动作，构建一个状态-动作 Q 值表。Q 表的更新采用以下公式：

$$Q(s, a) = Q(s, a) + \alpha [r + \gamma \max_{a'} Q(s', a') - Q(s, a)] \quad (7)$$

其中，学习率  $\alpha = 0.1$ ，折扣因子  $\gamma = 0.25$ 。奖励函数定义为：若新解优于原解，则  $r = 1$ ；否则  $r = -1$ 。行为选择采用  $\varepsilon$ -贪婪策略，以概率  $\varepsilon$  选择 Q 值最大的行为，以概率  $1 - \varepsilon$  随机选择行为。贪婪因子  $\varepsilon$  初始值为 0.9，随着迭代进行逐渐减小，以平衡探索与开发。

本文采用了“动作编码状态”简化策略，其核心思想是将智能体的行为选择本身作为状态标识，从而避免了传统 Q 学习中需要设计复杂状态离散化函数的麻烦。具体来说，算法初始化时为每个个体分配一个状态变量  $X\_State$ ，其初始值全部设为 1。在每一轮迭代中，个体首先根据自己当前的状态值查询 Q 表中对应的行，然后使用  $\varepsilon$  贪婪策略选择下一个要执行的动作。这个动作的编号直接决定了个体接下来的行为模式。并且，当动作执行完毕、环境反馈奖励之后，算法会将个体的状态直接更新为刚刚执行的动作编号，保证下一时刻的状态完全由当前时刻的动作选择所决定。

为避免 Q 表陷入局部最优，算法设计了 Q 表重置机制。当连续多代最优解没有改善时，以一定概率重置 Q 表的部分或全部行，重新探索行为选择策略。

## 4. 实验与分析

### 4.1. 实验设置

为验证 QLAB-PO 算法的有效性, 选取 CEC2017 测试函数上的 30 个标准测试函数进行实验。对比算法包括: 原始 PO 算法[5]、粒子群优化算法(PSO) [2]、灰狼优化算法(GWO) [3]、鲸鱼优化算法(WOA) [4]和飞蛾扑火算法(MFO) [13]。

实验参数设置如下: 种群规模  $N=30$ , 最大判断次数  $T=N \times 10000$ , 维度  $\text{dim} = 30$ 。所有算法独立运行 30 次, 记录最优值、最差值、平均值和标准差并进行比较分析。

### 4.2. 参数敏感性分析

为验证关键参数在不同取值下对算法性能的影响, 本文通过对 Q 学习的关键参数进行敏感性分析, 进行分析的参数为: 贪婪值  $g$ 、学习率  $lr$  和衰减率  $dr$ , 分别设值如下:  $g \in \{0.1, 0.9, 1\}$ ,  $lr \in \{0.01, 0.1, 0.5\}$ ,  $dr \in \{0.01, 0.25, 0.5\}$ , 分别取单峰函数 F3, 多峰函数 F12、F20 以及混合函数 F27, 进行分别独立运行 30 次, 将运行结果的每个函数进行 Friedman 排名, 最后将排名结果相加, 实验结果如图 2 所示。




Figure 2. Convergence curve of QLAB-PO under 12 test functions

图 2. QLAB-PO 在 12 个测试函数下的收敛曲线


当贪婪值  $g = 0.9$ 、学习率  $lr = 0.1$  和衰减率  $dr = 0.25$  时, 算法在所选函数中排名最佳, 所选参数具有一定合理性。

### 4.2. 算法结果分析

从表 1 中可以看出, QLAB-PO 算法在大多数测试函数上均取得了较高的排名且在绝大多数函数上获得了最小平均值, 特别是通过 Wilcoxon 秩与原来的 PO 算法相比其在所有测试函数上取得更好的结果, 尤其在测试函数 F23 到 F29 均取得最优值, 且观察到符号“+”和“≈”总的出现频率远远高于符号“-”, 可见 QLAB-PO 算法的性能优势明显, 表明其具有更强的全局搜索能力和逃离局部最优的能力, 在绝大多数测试函数上均显著优于其他对比算法。实验结果的最优值、最差值、平均值和标准差见附表 A1。

**Table 1.** Results of QLAB-PO compared with other algorithms under the CEC2017 test function  
**表 1.** QLAB-PO 在 CEC2017 测试函数下与其他算法比较的结果数据

	QLAB-PO	PO	PSO	GWO	WOA	MFO
平均水平	1.3333	4.6333	3.1667	2.9333	4.1333	4.8000
平均结果	1	5	3	2	4	6
+/-/~	~	30/0/0	28/1/1	20/3/7	28/0/2	30/0/0



**Figure 3.** Convergence curve of QLAB-PO under 12 test functions  
**图 3.** QLAB-PO 在 12 个测试函数下的收敛曲线

### 4.3. 收敛曲线分析

图 3 显示了各算法在部分代表性测试函数上的收敛曲线。可以看出,QLAB-PO 算法的收敛速度明显快于其他对比算法,且能够收敛到更优的解。尤其在 F12 函数中 QLAB-PO 能在前期跳出局部最优,快速向全局最优收敛。这得益于 Q 学习机制的自适应行为选择能力,使算法能够根据搜索状态动态调整搜索策略,使得在各种环境下在保证探索能力的同时加快收敛。

## 5. 结论

本文针对鸚鵡优化算法在复杂优化问题中存在的探索与开发平衡能力不足、易陷入局部最优等局限性,提出了一种基于 Q 学习的自适应行为选择鸚鵡优化算法。该算法创新性地将强化学习中的 Q 学习机制引入元启发式算法框架,通过构建行为选择 Q 表,使算法能够根据当前搜索状态自适应地选择相应的行为策略,从而实现了搜索过程中探索与开发的动态平衡。

在算法设计方面,QLAB-PO 在原始 PO 算法的基础上添加了两种新的行为模式,丰富了算法的搜索策略多样性。通过 Q 学习机制,算法能够根据历史搜索经验动态评估不同行为策略的效用,并实时调整行为选择概率,使算法在搜索初期倾向于全局探索,而在搜索后期逐渐转向局部开发,算法实现了从静态预设策略到动态自适应策略的转变,这种数据驱动的行为选择方式不仅提升了算法的优化性能,也增强了其对不同问题特征的适应能力。同时,为避免 Q 表陷入局部最优导致的早熟收敛问题,本文设计了 Q 表重置机制,当检测到算法停滞时自动重置 Q 值,重新激发算法的探索能力,有效增强了算法的全局搜索性能和鲁棒性,为解决强化学习中常见的探索-利用困境提供了有效解决方案。

在 30 个标准测试函数上的实验结果表明,QLAB-PO 算法在收敛速度和求解精度上均显著优于原始 PO 算法及其他比较算法。

尽管 QLAB-PO 算法在标准测试函数上取得了良好的优化效果,但仍存在进一步研究的空间。未来的研究方向包括:(1) 将 QLAB-PO 算法应用于实际工程优化问题;(2) 探索深度强化学习在元启发式算法中的应用;(3) 研究多目标优化场景下的自适应行为选择策略。

## 参考文献

- [1] Macready, W.G. and Wolpert, D.H. (1996) What Makes an Optimization Problem Hard? *Complexity*, **1**, 40-46. <https://doi.org/10.1002/cplx.6130010511>
- [2] Kennedy, J. and Eberhart, R. (1995) Particle Swarm Optimization. *Proceedings of ICNN'95—International Conference on Neural Networks*, Vol. 4, 1942-1948. <https://doi.org/10.1109/icnn.1995.488968>
- [3] Mirjalili, S., Mirjalili, S.M. and Lewis, A. (2014) Grey Wolf Optimizer. *Advances in Engineering Software*, **69**, 46-61. <https://doi.org/10.1016/j.advengsoft.2013.12.007>
- [4] Mirjalili, S. and Lewis, A. (2016) The Whale Optimization Algorithm. *Advances in Engineering Software*, **95**, 51-67. <https://doi.org/10.1016/j.advengsoft.2016.01.008>
- [5] Lian, J., Hui, G., Ma, L., Zhu, T., Wu, X., Heidari, A.A., et al. (2024) Parrot Optimizer: Algorithm and Applications to Medical Problems. *Computers in Biology and Medicine*, **172**, Article ID: 108064. <https://doi.org/10.1016/j.compbiomed.2024.108064>
- [6] Watkins, C.J.C.H. and Dayan, P. (1992) Q-Learning. *Machine Learning*, **8**, 279-292. <https://doi.org/10.1007/bf00992698>
- [7] Yang, Y., Gao, Y., Ding, Z., Wu, J., Zhang, S., Han, F., et al. (2024) Advancements in Q-Learning Meta-Heuristic Optimization Algorithms: A Survey. *WIREs Data Mining and Knowledge Discovery*, **14**, e1548. <https://doi.org/10.1002/widm.1548>
- [8] Li, Y., Wang, H., Fan, J. and Geng, Y. (2022) A Novel Q-Learning Algorithm Based on Improved Whale Optimization Algorithm for Path Planning. *PLOS ONE*, **17**, e0279438. <https://doi.org/10.1371/journal.pone.0279438>
- [9] Meerza, S.I.A., Islam, M. and Uzzal, M.M. (2019) Q-Learning Based Particle Swarm Optimization Algorithm for Optimal Path Planning of Swarm of Mobile Robots. 2019 1st International Conference on Advances in Science, Engineering and

- 
- Robotics Technology (ICASERT)*, Dhaka, 3-5 May 2019, 1-5. <https://doi.org/10.1109/icasert.2019.8934450>
- [10] Kazikova, A., Pluhacek, M. and Senkerik, R. (2018) Performance of the Bison Algorithm on Benchmark IEEE CEC 2017. In: Silhavy, R., Ed., *Artificial Intelligence and Algorithms in Intelligent Systems*, Springer International Publishing, 445-454. [https://doi.org/10.1007/978-3-319-91189-2\\_44](https://doi.org/10.1007/978-3-319-91189-2_44)
- [11] Zhao, W., Wang, L., Zhang, Z., Mirjalili, S., Khodadadi, N. and Ge, Q. (2023) Quadratic Interpolation Optimization (QIO): A New Optimization Algorithm Based on Generalized Quadratic Interpolation and Its Applications to Real-World Engineering Problems. *Computer Methods in Applied Mechanics and Engineering*, **417**, Article ID: 116446. <https://doi.org/10.1016/j.cma.2023.116446>
- [12] 高鑫宇. 基于自适应知识迁移的多因子进化算法研究与应用[D]: [硕士学位论文]. 西安: 西安理工大学, 2024.
- [13] Mirjalili, S. (2015) Moth-Flame Optimization Algorithm: A Novel Nature-Inspired Heuristic Paradigm. *Knowledge-Based Systems*, **89**, 228-249. <https://doi.org/10.1016/j.knosys.2015.07.006>

## 附录

Table A1. The algorithm's min, max, mean, and std deviation under the CEC2017 test function.

表 A1. 算法在 CEC2017 测试函数下最优值、最差值、平均值和标准差

F	算法	max	min	mean	std
F1	QLAB-PO	8.1935e+03	106.9440	2.2506e+03	2.3716e+03
	PO	2.2629e+10	2.9182e+09	8.6303e+09	4.6191e+09
	PSO	1.6176e+08	1.1190e+08	1.4218e+08	1.3907e+07
	GWO	9.4274e+09	2.0363e+08	3.7214e+09	2.8588e+09
	WOA	3.8731e+07	1.0432e+06	4.2271e+06	7.1002e+06
	MFO	2.6353e+10	4.1003e+09	1.1275e+10	5.8986e+09
F2	QLAB-PO	47704	200	3.1187e+03	8.5648e+03
	PO	3.0436e+34	2.9722e+26	3.8233e+33	8.2696e+33
	PSO	4.5540e+13	1.0853e+11	5.4389e+12	9.9170e+12
	GWO	3.2153e+30	1.0776e+21	1.5350e+29	5.9202e+29
	WOA	2.4182e+30	1.0464e+19	8.5389e+28	4.4081e+29
	MFO	1.5769e+46	9.1367e+19	5.2574e+44	2.8790e+45
F3	QLAB-PO	333.0741	300.0000	301.1211	6.0351
	PO	1.0212e+05	5.7963e+04	8.1486e+04	1.1941e+04
	PSO	710.8866	507.2297	629.0236	50.0109
	GWO	5.3901e+04	1.8751e+04	3.4572e+04	8.9307e+03
	WOA	2.1515e+04	5.5587e+03	1.2918e+04	4.2689e+03
	MFO	2.2539e+05	300.0161	8.2837e+04	5.8207e+04
F4	QLAB-PO	576.3473	403.0448	486.5533	33.2439
	PO	1.7400e+03	760.6752	1.0001e+03	192.4865
	PSO	570.9180	429.1258	463.9561	38.0928
	GWO	784.6621	512.4687	624.0825	63.0212
	WOA	673.5329	483.8582	566.6120	50.6874
	MFO	3.8655e+03	482.0224	1.4236e+03	968.3716
F5	QLAB-PO	687.0510	556.7126	608.7710	39.0505
	PO	821.7481	665.5382	736.1092	33.7079
	PSO	749.5936	643.5961	693.7975	26.6118
	GWO	628.1663	559.4776	593.9754	20.0432
	WOA	842.6370	597.2988	701.5574	59.1326
	MFO	827.9336	603.4754	723.0041	48.0801

续表

F6	QLAB-PO	637.8936	600.5817	612.5202	10.3125
	PO	681.1837	646.1720	661.3695	7.1788
	PSO	654.0375	612.7894	635.8213	11.0898
	GWO	614.0044	601.0496	606.8324	3.4444
	WOA	681.4639	644.7239	660.8823	9.9258
	MFO	670.1268	618.9526	640.0859	13.2450
F7	QLAB-PO	1.1133e+03	792.6027	880.5685	89.8227
	PO	1.4918e+03	1.1115e+03	1.3056e+03	90.3724
	PSO	940.7456	894.8272	918.9639	13.2737
	GWO	984.4907	803.2854	876.3544	48.4584
	WOA	1.5642e+03	1.0791e+03	1.2702e+03	114.6288
	MFO	1.5262e+03	920.1629	1.1734e+03	167.3643
F8	QLAB-PO	999.9847	843.7781	907.4637	49.8873
	PO	1.2511e+03	1.0307e+03	1.1201e+03	44.8746
	PSO	1.2094e+03	981.4720	1.0637e+03	48.4003
	GWO	978.9859	849.2967	898.2341	33.8720
	WOA	1.2179e+03	1.0254e+03	1.1089e+03	53.8430
	MFO	1.0821e+03	913.4248	994.0077	44.5004
F9	QLAB-PO	5.2425e+03	1.0532e+03	2.2126e+03	1.3992e+03
	PO	1.2451e+04	6.9112e+03	9.0465e+03	1.5729e+03
	PSO	1.0832e+04	978.4272	5.9349e+03	2.1124e+03
	GWO	5.5362e+03	1.3072e+03	2.5549e+03	1.0342e+03
	WOA	2.1417e+04	4.3794e+03	9.3475e+03	3.8310e+03
	MFO	1.3831e+04	2.7749e+03	7.8965e+03	2.7865e+03
F10	QLAB-PO	5.8971e+03	2.6458e+03	4.3284e+03	704.8629
	PO	8.2572e+03	5.3702e+03	7.0876e+03	657.4708
	PSO	7.5796e+03	4.4930e+03	5.6192e+03	686.3673
	GWO	7.5579e+03	2.5953e+03	3.8077e+03	880.6037
	WOA	6.9944e+03	4.6710e+03	6.0020e+03	738.0995
	MFO	6.9756e+03	3.5197e+03	5.1139e+03	770.4340

续表

F11	QLAB-PO	1.3448e+03	1.1280e+03	1.2148e+03	54.4480
	PO	8.4491e+03	2.7522e+03	5.3824e+03	1.3385e+03
	PSO	1.4555e+03	1.2885e+03	1.3634e+03	44.7584
	GWO	9.8968e+03	1.4019e+03	3.3124e+03	2.2445e+03
	WOA	1.7557e+03	1.3443e+03	1.5095e+03	105.1521
	MFO	3.2967e+04	1.5723e+03	9.1750e+03	9.0057e+03
F12	QLAB-PO	3.4882e+05	3.2765e+03	5.5539e+04	7.2316e+04
	PO	1.4010e+09	1.7320e+08	5.8037e+08	3.2477e+08
	PSO	1.5399e+08	3.1226e+07	7.6727e+07	2.8460e+07
	GWO	1.8120e+08	6.7829e+07	1.3560e+08	2.5994e+07
	WOA	2.4835e+08	4.7754e+06	1.2177e+08	6.4637e+07
	MFO	3.3798e+09	1.0948e+06	6.2345e+08	8.1654e+08
F13	QLAB-PO	9.5927e+03	1.6662e+03	3.7888e+03	1.8665e+03
	PO	1.7620e+08	2.2858e+05	4.1311e+07	4.4538e+07
	PSO	4.9241e+06	9.0393e+05	2.6379e+06	7.9145e+05
	GWO	7.6351e+07	5.6123e+04	1.6335e+07	2.6848e+07
	WOA	4.3052e+05	1.8951e+04	1.1961e+05	1.1072e+05
	MFO	1.3363e+09	1.2477e+04	1.2471e+08	3.5586e+08
F14	QLAB-PO	1.7084e+03	1.4854e+03	1.5816e+03	48.2553
	PO	2.6141e+06	2.7936e+04	8.9729e+05	7.5399e+05
	PSO	9.9825e+04	6.7693e+03	3.3298e+04	2.1146e+04
	GWO	3.6999e+05	1.8528e+03	1.1036e+05	1.3347e+05
	WOA	8.0201e+05	9.3504e+03	2.7421e+05	2.0045e+05
	MFO	1.3918e+07	1.7564e+03	6.5004e+05	2.5429e+06
F15	QLAB-PO	7.6112e+03	1.6042e+03	2.6713e+03	1.2499e+03
	PO	1.4239e+06	4.2314e+04	3.0920e+05	3.6134e+05
	PSO	5.6153e+05	2.5786e+04	3.0643e+05	1.3491e+05
	GWO	6.0086e+04	6.0272e+03	2.0300e+04	1.3900e+04
	WOA	4.0809e+05	4.6118e+03	6.4055e+04	8.5331e+04
	MFO	1.2616e+05	4.4765e+03	3.7038e+04	2.9130e+04

续表

F16	QLAB-PO	3.2327e+03	1.7497e+03	2.4072e+03	348.9439
	PO	4.4104e+03	2.8223e+03	3.5670e+03	513.0583
	PSO	3.2105e+03	2.3512e+03	2.7129e+03	220.2373
	GWO	2.6790e+03	1.8655e+03	2.2090e+03	238.4371
	WOA	4.0808e+03	2.1840e+03	3.0892e+03	460.3610
	MFO	4.2179e+03	2.5282e+03	3.1992e+03	401.8000
F17	QLAB-PO	2.3400e+03	1.7657e+03	1.9234e+03	140.3771
	PO	3.4685e+03	2.2257e+03	2.6935e+03	351.8547
	PSO	3.0518e+03	2.0030e+03	2.4282e+03	241.7692
	GWO	2.1353e+03	1.7808e+03	1.9525e+03	94.5629
	WOA	3.2994e+03	2.1782e+03	2.6775e+03	310.8352
	MFO	2.9858e+03	2.1330e+03	2.4906e+03	213.8843
F18	QLAB-PO	9.8719e+04	6.4526e+03	2.5313e+04	1.8491e+04
	PO	1.4155e+07	2.8816e+05	4.7036e+06	3.6042e+06
	PSO	1.3279e+05	3.4553e+04	7.0290e+04	2.5945e+04
	GWO	2.4903e+06	2.0872e+04	5.4854e+05	6.8871e+05
	WOA	1.2151e+07	2.5262e+05	2.9940e+06	2.5881e+06
	MFO	4.4195e+06	1.6337e+04	5.2106e+05	1.0483e+06
F19	QLAB-PO	1.2956e+04	1.9792e+03	4.0392e+03	2.8661e+03
	PO	1.0491e+07	1.2028e+05	2.7714e+06	2.8372e+06
	PSO	1.0683e+06	1.3415e+05	4.0662e+05	2.3025e+05
	GWO	9.3095e+06	2.7547e+03	3.7550e+05	1.6909e+06
	WOA	3.0790e+06	3.9782e+03	7.2407e+05	7.5010e+05
	MFO	7.3032e+06	2.0787e+03	7.6809e+05	2.2164e+06
F20	QLAB-PO	2.7834e+03	2.1340e+03	2.4731e+03	154.8161
	PO	3.1908e+03	2.4672e+03	2.8135e+03	177.9018
	PSO	2.9590e+03	2.3465e+03	2.6149e+03	180.4662
	GWO	2.7567e+03	2.1631e+03	2.3575e+03	155.5425
	WOA	3.0413e+03	2.5007e+03	2.7439e+03	139.6758
	MFO	3.3013e+03	2.3337e+03	2.7106e+03	222.2927

续表

F21	QLAB-PO	2.2508e+03	2.1689e+03	2.2205e+03	32.0878
	PO	3.0059e+03	2250	2.5430e+03	250.6095
	PSO	2.2737e+03	2.1325e+03	2.2057e+03	47.4276
	GWO	2.5319e+03	2.2089e+03	2.2944e+03	64.0750
	WOA	2.3158e+03	2.2023e+03	2.2608e+03	23.6324
	MFO	6.2139e+03	2.1878e+03	2.7776e+03	873.8728
F22	QLAB-PO	2.4527e+03	2.2507e+03	2.3259e+03	44.0384
	PO	2.5655e+03	2350	2.4410e+03	71.5019
	PSO	2.4878e+03	2.3500e+03	2.4041e+03	44.0978
	GWO	2.3500e+03	2.2664e+03	2.3129e+03	31.4122
	WOA	2.6352e+03	2.3227e+03	2.4144e+03	76.2963
	MFO	2.5014e+03	2.3300e+03	2.3938e+03	43.6225
F23	QLAB-PO	2500	2500	2500	0
	PO	2.5000e+03	2.5000e+03	2.5000e+03	3.1101e-04
	PSO	5.4168e+03	3.2107e+03	4.6205e+03	511.2225
	GWO	3.0130e+03	2.8299e+03	2.8804e+03	41.8703
	WOA	3.4635e+03	2.9537e+03	3.1264e+03	125.7941
	MFO	3.0197e+03	2.9344e+03	2.9710e+03	22.8556
F24	QLAB-PO	2600	2600	2600	0
	PO	2.6000e+03	2600	2.6000e+03	5.6295e-04
	PSO	2.6723e+03	2.6617e+03	2.6676e+03	2.4404
	GWO	3.5568e+03	2.6000e+03	3.0579e+03	344.1775
	WOA	3.8600e+03	2600	2.8330e+03	474.3684
	MFO	3.5774e+03	3.4336e+03	3.5028e+03	37.3300
F25	QLAB-PO	2700	2700	2700	0
	PO	2.7000e+03	2700	2.7000e+03	0.0070
	PSO	3.3204e+03	2.9166e+03	2.9576e+03	77.6828
	GWO	3.4217e+03	3.0760e+03	3.1960e+03	84.5995
	WOA	3.0776e+03	2700	2.7249e+03	94.8383
	MFO	6.2388e+03	2.9197e+03	3.5817e+03	802.9432

续表

F26	QLAB-PO	2800	2800	2800	0
	PO	2.8000e+03	2800	2.8000e+03	0.0084
	PSO	3.4580e+03	3.0283e+03	3.3845e+03	72.6427
	GWO	6.2244e+03	2.8000e+03	5.2422e+03	764.5287
	WOA	1.0005e+04	2800	3.8324e+03	2.3744e+03
	MFO	7.8021e+03	5.6375e+03	6.5737e+03	556.3917
F27	QLAB-PO	2900	2900	2900	0
	PO	2.9000e+03	2900	2.9000e+03	0.0024
	PSO	6.5863e+03	3.1815e+03	4.7559e+03	873.9973
	GWO	3.9800e+03	3.4851e+03	3.6999e+03	127.3991
	WOA	4.3937e+03	3.5638e+03	3.9288e+03	200.1890
	MFO	3.9630e+03	3.4845e+03	3.6089e+03	103.6543
F28	QLAB-PO	3000	3000	3000	0
	PO	3.0001e+03	3000	3.0000e+03	0.0242
	PSO	3.3807e+03	3.2355e+03	3.2951e+03	39.3830
	GWO	5.2931e+03	3.3259e+03	3.8216e+03	536.0915
	WOA	5.2340e+03	3000	3.1445e+03	419.6155
	MFO	6.0632e+03	3.1554e+03	5.1195e+03	568.0444
F29	QLAB-PO	3100	3100	3100	0
	PO	3.1001e+03	3100	3.1000e+03	0.0363
	PSO	4.5440e+03	3.4926e+03	4.0144e+03	281.8470
	GWO	3.8550e+03	3.2779e+03	3.5266e+03	154.3573
	WOA	5.5377e+03	3100	4.3379e+03	505.7328
	MFO	4.5205e+03	3.5798e+03	4.1085e+03	239.1453
F30	QLAB-PO	2.9121e+04	3200	4.9043e+03	5.3401e+03
	PO	7.1294e+05	3.2000e+03	2.7808e+04	1.2945e+05
	PSO	4.9612e+06	1.2975e+06	2.6436e+06	1.0931e+06
	GWO	9.0416e+06	1.6328e+04	8.0935e+05	1.7230e+06
	WOA	3.7776e+07	3200	3.3056e+06	6.8473e+06