

基于三支决策的海洋捕食者算法

房晶^{1a}, 万仁霞^{1a,b}, 苗夺谦^{1b,2}

(1.北方民族大学 a.数学与信息科学学院; b.宁夏智能信息与大数据处理重点实验室,银川 750021;
2.同济大学 电子与信息工程学院,上海 201804)

摘要:针对海洋捕食者算法(marine predator algorithm, MPA)收敛速度慢、求解精度低、易陷入局部最优等缺陷,提出一种基于三支决策的海洋捕食者算法(TWD-MPA).算法根据个体间距离之比将猎物对象划分为正域、负域和边界域,并分别采取不同策略对3个域中的猎物进行更新.引入的步长控制策略和惯性权重系数策略有效平衡算法的勘探与开发能力.在10个基准测试函数上,将TWD-MPA与其他7种优化算法进行实验对比,并通过收敛性分析、稳定性分析和统计性分析对算法进行性能评价.结果表明,相较于其他算法,TWD-MPA在求解精度、收敛速度和稳定性等方面具有明显优势.

关键词:海洋捕食者算法;三支决策;步长控制;惯性权重;边界域

中图分类号:TP181

文献标志码:A

文章编号:1000-2367(2025)04-0049-09

海洋捕食者算法(marine predator algorithm, MPA)是FARAMARZI等^[1]于2020年提出的一种新型的基于种群的元启发式算法.该算法的灵感来自海洋捕食者在不同速度比下的觅食策略,即莱维飞行和布朗运动,以及捕食者与猎物之间最佳相遇率策略.海洋捕食者算法求解优化问题时具有显著的寻优能力,但与其他基于种群的元启发式算法一样,仍然存在易陷入局部最优、寻优精度低和收敛速度慢等缺陷^[2].因此,国内外学者对海洋捕食者算法进行了更深入的研究,主要从3个方面进行改进:(1)修改参数调整方案.例如,HOUSSEIN等^[3]提出了一种改进的海洋捕食者算法,将步长控制参数CF的动态调整方案由指数形式修改为正弦指数形式.FAN等^[4]提出了一种非线性步长控制参数和惯性权重系数,并结合逻辑对立学习机制改进MPA,以平衡算法的勘探与开发,加快算法收敛.(2)改进位置更新规则.例如,付华等^[5]提出了一种阶段化改进的海洋捕食者算法,通过不同策略改进MPA3个阶段的位置更新规则,以提高算法的寻优性能.SADIQ等^[6]提出了一种非线性的海洋捕食者算法,在MPA的位置更新方程上增加了一个非线性参数,以平衡算法的勘探与开发.(3)与经典算法相结合.例如,HOUSSEIN等^[7]将对立学习策略、灰狼优化算法与海洋捕食者算法相融合,提高了算法的收敛速度及局部搜索效率.SHAHEEN等^[8]将粒子群算法与海洋捕食者算法相结合,使得算法的寻优性能显著增强.

尽管上述改进算法一定程度上提高了海洋捕食者算法的寻优性能,但算法存在的“过度聚集”现象,求解精度低、收敛速度慢以及易陷入局部最优等问题仍一定程度存在.本文提出了一种基于三支决策的海洋捕食

收稿日期:2024-04-12; **修回日期:**2024-06-14.

基金项目:国家自然科学基金(62066001);宁夏科技领军人才项目(2022GKLRLX08);宁夏自然科学基金(2021AAC03203).

作者简介:房晶(1997—),女,山西运城人,北方民族大学硕士研究生,研究方向为三支决策、数据分析及智能算法,
E-mail:fangjing555@126.com.

通信作者:万仁霞(1975—),男,江西南昌人,北方民族大学教授,博士生导师,研究方向为信息系统、数据挖掘、知识学习
和粒计算,E-mail:wanrx1022@126.com.

引用本文:房晶,万仁霞,苗夺谦.基于三支决策的海洋捕食者算法[J].河南师范大学学报(自然科学版),2025,53(4):
49-57.(Fang Jing, Wan Renxia, Miao Duoqian. Marine predator algorithm based on three-way decision[J]. Journal
of Henan Normal University(Natural Science Edition), 2025, 53(4): 49-57. DOI: 10.16366/j.cnki.1000-
2367.2024.04.12.0002.)

者算法(marine predator algorithm based on three-way decision, TWD-MPA),通过调整步长控制参数、引入惯性权重系数来改进位置更新规则,结合三支决策核心思想,将猎物划分为 3 个域并采取不同规则更新位置,以加强个体间信息交流,增强算法勘探与开发能力,从而提升算法寻优性能.

1 相关理论

1.1 海洋捕食者算法

海洋捕食者算法是一种建立在三阶段搜索结构上的优化算法,通过两种觅食策略的优化调控来提高捕食者与猎物的相遇率,从而提升算法的寻优效率.数学模型描述如下.

1.1.1 MPA 的初始化

与大多数元启发式算法相似,海洋捕食者算法的初始解均匀地分布在搜索空间上^[9],初始种群位置更新规则如下: $X_0 = X_{\min} + \text{rand}(X_{\max} - X_{\min})$, 其中, X_{\max} 和 X_{\min} 分别表示搜索空间的上界与下界, rand 表示均匀分布在 $[0,1]$ 的随机向量.

1.1.2 MPA 的寻优阶段

MPA 根据猎物与捕食者的速度比,同时考虑到种群的生命周期,将整个优化过程分为 3 个阶段:

(1) 高速比阶段:高速比阶段发生于整个迭代过程的前三分之一($t < T/3$),该阶段的主要任务是进行全局勘探.种群($i=1,2,\dots,N$)的更新规则如下: $\vec{S}_i = \vec{R}_B \otimes (\vec{E}_i - \vec{R}_B \otimes \vec{P}_i)$, $\vec{P}_i = \vec{P}_i + P \cdot \vec{R} \otimes \vec{S}_i$, 其中, t 为当前迭代次数, T 为最大迭代次数; \vec{S}_i 为猎物的移动步长; \vec{R}_B 表示服从布朗运动的随机向量; \vec{S} 表示均匀分布在 $[0,1]$ 的随机向量; $P = 0.5$; \vec{E}_i 为由顶级捕食者构造的精英矩阵; \vec{P}_i 为与精英矩阵具有相同维数的猎物矩阵.

(2) 等速比阶段:等速比阶段发生于整个迭代过程的三分之一到三分之二($T/3 \leq t \leq 2T/3$),该阶段代表种群从勘探到开发的过渡,此时勘探与开发同样重要.算法指定前一半种群($i=1,2,\dots,N/2$)进行勘探,其更新规则如下: $\vec{S}_i = \vec{R}_L \otimes (\vec{E}_i - \vec{R}_L \otimes \vec{P}_i)$, $\vec{P}_i = \vec{P}_i + P \cdot \vec{R} \otimes \vec{S}_i$, 后一半种群($i=N/2,\dots,N$)进行开发,其更新规则如下: $\vec{S}_i = \vec{R}_B \otimes (\vec{R}_B \otimes \vec{E}_i - \vec{P}_i)$, $\vec{P}_i = \vec{S}_i + P \cdot C_F \otimes \vec{S}_i$, 其中, \vec{R}_L 表示服从莱维飞行的随机向量; $C_F = (1-t/T)^{(2t/T)}$ 为步长控制参数,用于控制捕食者的移动步长.

(3) 低速比阶段:低速比阶段发生于整个迭代过程的后三分之一($t > 2T/3$),该阶段的主要任务是进行局部开发,此时捕食者的最佳策略是选择搜索步长较小的莱维飞行,种群($i=1,2,\dots,N$)的更新规则如下:

$$\vec{S}_i = \vec{R}_L \otimes (\vec{R}_L \otimes \vec{E}_i - \vec{P}_i), \vec{P}_i = \vec{E}_i + P \cdot C_F \otimes \vec{S}_i.$$

1.1.3 涡流形成与鱼类聚集装置效应

在自然环境中,海洋捕食者的猎食行为经常受到海洋涡旋或是鱼类聚集装置(fish aggregating devices, FADS),简记为 F_S 的显著影响.MPA 通过模拟鱼类聚集装置(F_S)的效应,减少陷入局部最优解的可能性并促进全局探索.其数学模型如下:

$$\vec{P}_i = \begin{cases} \vec{P}_i + C_F [\vec{X}_{\min} + \vec{R} \otimes (\vec{X}_{\max} - \vec{X}_{\min})] \otimes \vec{U}, & \text{若 } r \leq F_S, \\ \vec{P}_i + [F_S(1-r) + r](\vec{P}_{r1} - \vec{P}_{r2}), & \text{若 } r > F_S, \end{cases}$$

其中, \vec{U} 为只包含 0 和 1 的二进制向量数组; r 是 $[0,1]$ 间的均匀随机数; \vec{P}_{r1} 和 \vec{P}_{r2} 表示猎物矩阵的两个随机分量.

研究表明,当海洋中形成涡流或存在 F_S 时,海洋捕食者 80% 以上的时间都在 F_S 附近活动,产生“聚集现象”,这种现象对应算法陷入局部最优的情况;其余 20% 的时间捕食者会进行长距离的游动,以找到其他猎物存在的区域^[10],因此,通常用 $F_S=0.2$ 来刻画 FADs 效应影响优化过程的概率.

1.2 三支决策

三支决策(three-way decisions, TWD)理论是 YAO^[11]于 2010 年提出的一种新的决策理论.其核心思想是将一个整体划分为 3 部分,分别对每个部分采取不同的治理方式,来处理实际决策中出现的不确定问题.该理论基于决策粗糙集将整个论域划分为 3 个域,即正域(positive region, POS)、负域(negative region,

NEG)和边界域(boundary region, BND),分别代表接受、拒绝和延迟决策三种决策结果^[12].其基本思想是:假设状态集包含两种属于互补关系的状态,记为 $\Omega = \{X, \neg X\}$,分别表示对象属于 X 和属于 $\neg X$;决策集包含 3 种不同的决策,记为 $A = \{P, B, N\}$,分别表示对象被划分到 3 个域的 3 种决策行为,即正域接受、边界域延迟和负域拒绝 3 种决策.通过引入阈值 $\alpha, \beta (0 < \beta < \alpha < 1)$,结合 Bayes 决策的推导过程,得到三支决策的规则如下:若 $P(X | [x]_R) \geq \alpha$,则 $x \in \text{POS}(X)$;若 $\beta < P(X | [x]_R) < \alpha$,则 $x \in \text{BND}(X)$;若 $P(X | [x]_R) \leq \beta$,则 $x \in \text{NEG}(X)$.

2 基于三支决策的海洋捕食者算法

本节针对 MPA 存在的缺陷,通过调整步长控制参数、引入惯性权重系数等措施,并结合三支决策基本思想,来改进海洋捕食者算法.

2.1 步长控制参数策略

在 MPA 的寻优过程中,步长控制参数的设置将直接影响到算法勘探与开发的平衡.迭代前期步长控制参数的值较大,将有利于对整个搜索空间进行探索;而迭代后期步长控制参数的值较小,有利于提高算法对局部区域的开发能力^[4].为此,本文引入了一种新的步长控制参数,定义如下:

$$C_{F\text{New}} = \left(1 - \frac{1}{1 + e^{-10(\frac{t}{T} - \frac{1}{2})}}\right)^{\left(\frac{2+t}{T}\right)}.$$

在迭代过程中, $C_{F\text{New}}$ 以指数形式从 1 减小到 0.为了验证 $C_{F\text{New}}$ 的有效性,本文将其与原始 MPA 步长控制参数 $C_{F\text{MPA}}$ 以及文献[4]提出的步长控制参数 $C_{F\text{MMPA}} = \cos((\pi/2) \cdot (t/T))^{2t/T}$ 进行比较,如图 1 所示.由图 1 可知,本文提出的步长控制参数 $C_{F\text{New}}$ 在迭代前期缓慢减小,使得猎物可以以较大的步长进行全局勘探,从而增强算法勘探能力;在迭代中期快速减小,以加快算法收敛速度;在迭代后期缓慢减小,使得猎物在一定时间内以较小的步长进行局部开发,提升算法开发能力.

2.2 惯性权重系数策略

改进步长控制参数虽可以提升算法勘探与开发能力,但也会使得算法从勘探到开发的过渡阶段转变突然,容易跳过最优解而陷入局部最优.因此,为了进一步平衡勘探与开发,本文在算法迭代前期与中期引入惯性权重系数 w ,定义如下: $w = \exp(-(\frac{6 \cdot t}{T})^2)$,惯性权重系数 w 在迭代的过程中以指数形式下降.惯性权重系数的这种非线性变化可以有效平衡猎物(顶级猎食者)在算法迭代前期和中期对猎物自身影响.

综上,根据上述步长控制参数 $C_{F\text{New}}$ 和惯性权重系数 w ,得到新的位置更新方程.在高速比阶段,即 $t < T/3$ 时,种群($i = 1, 2, \dots, N$)的更新规则被改进为:

$$\vec{S}_i = \vec{R}_B \otimes (\vec{E}_i - \vec{R}_B \otimes \vec{P}_i), \vec{P}_i = w \cdot \vec{P}_i + P \cdot C_{F\text{New}} \otimes \vec{S}_i, \quad (1)$$

在等速比阶段,即 $T/3 \leq t \leq 2T/3$ 时,前一半种群($i = 1, 2, \dots, N/2$)的更新规则被改进为:

$$\vec{S}_i = \vec{R}_L \otimes (\vec{E}_i - \vec{R}_L \otimes \vec{P}_i), \vec{P}_i = w \cdot \vec{P}_i + P \cdot C_{F\text{New}} \otimes \vec{S}_i, \quad (2)$$

后一半种群($i = N/2, \dots, N$)的更新规则被改进为:

$$\vec{S}_i = \vec{R}_B \otimes (\vec{R}_B \otimes \vec{E}_i - \vec{P}_i), \vec{P}_i = w \cdot \vec{E}_i + P \cdot C_{F\text{New}} \otimes \vec{S}_i, \quad (3)$$

在低速比阶段,即 $t > 2T/3$ 时,种群($i = 1, 2, \dots, N$)的更新规则被改进为:

$$\vec{S}_i = \vec{R}_L \otimes (\vec{R}_L \otimes \vec{E}_i - \vec{P}_i), \vec{P}_i = \vec{E}_i + P \cdot C_{F\text{New}} \otimes \vec{S}_i, \quad (4)$$

考虑 FADs 效应,新的数学模型如下:

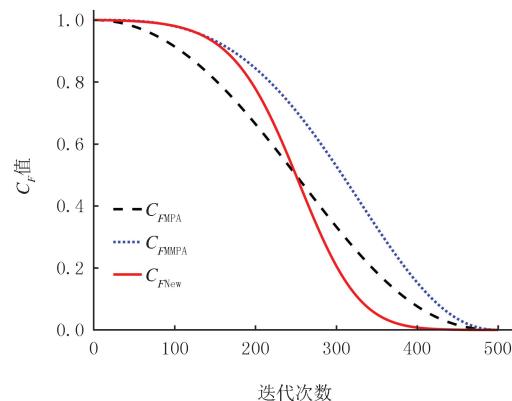


图1 步长控制参数的变化曲线

Fig. 1 Variation curve of step size control parameter

$$\vec{P}_i = \begin{cases} \vec{P}_i + C_{F\text{New}} [\vec{X}_{\min} + \vec{R} \otimes (\vec{X}_{\max} - \vec{X}_{\min})] \otimes \vec{U}, & \text{若 } r \leq F_s, \\ \vec{P}_i + [F_s(1-r) + r](\vec{P}_{r1} - \vec{P}_{r2}), & \text{若 } r > F_s. \end{cases} \quad (5)$$

2.3 三支学习搜索策略

种群多样性对算法的寻优精度和收敛速度起着关键作用,但在 MPA 迭代过程中,种群中所有个体均向顶级捕食者靠近,导致种群多样性随着算法迭代逐渐降低,这在解决高维复杂问题时往往会导致局部最优。因此,为了确保种群多样性,避免“过度聚集”现象,本文提出了三支学习搜索策略,在算法每次迭代完成后,根据随机猎物与当前猎物的距离、顶级捕食者与当前猎物反向解的距离以及这两个距离的比值将猎物划分为 3 类,并结合三支决策核心思想制定新的规则来更新猎物位置,最后通过比较猎物更新前后的适应度值来择优和迭代。具体策略如下:

首先,通过反向学习得到猎物反向解,根据个体间的距离之比设置猎物的划分依据,即:

$$\vec{P}_r^{\text{obl}} = \vec{X}_{\min} + \vec{X}_{\max} - \vec{P}_r, \quad (6)$$

$$E_1 = \| \vec{P}_i - \vec{P}_r \|, \quad (7)$$

$$E_2 = \| \vec{E}_i - \vec{P}_r^{\text{obl}} \|, \quad (8)$$

其中, \vec{P}_r 为当前猎物; \vec{P}_r^{obl} 为当前猎物反向解; \vec{P}_i 为随机猎物; \vec{E}_i 为顶级捕食者。式(6)表示当前猎物的反向解;式(7)表示随机猎物与当前猎物的距离;式(8)表示顶级捕食者与当前猎物反向解的距离;这两个距离的比值 E_1/E_2 将作为猎物的划分依据。

其次,根据距离之比 E_1/E_2 将猎物分为正域、负域和边界域。结合三支决策的猎物分域规则如下:若 $E_1/E_2 \leq \beta$,则 $\vec{P}_i \in \text{NEG}(\vec{P})$;若 $\beta < E_1/E_2 < \alpha$,则 $\vec{P}_i \in \text{BND}(\vec{P})$;若 $E_1/E_2 \geq \alpha$,则 $\vec{P}_i \in \text{POS}(\vec{P})$ 。其中,NEG、BND 和 POS 分别为负域、边界域和正域。分域完成后,分别执行不同的规则更新 3 个域中的猎物。

在负域中,猎物向顶级捕食者学习,同时结合当前猎物反向解进行更新。利用顶级捕食者更新位置,可以使得猎物不断趋向当前的全局最优,有助于提高算法的勘探能力。公式如下:

$$\vec{P}_i^c = \vec{P}_i + \vec{P}_r^{\text{obl}} + \vec{E}_i, \quad (9)$$

其中, \vec{P}_i^c 是更新后得到的猎物。

在边界域中,根据三支决策中“延迟决策”思想,猎物不进行更新,待下一次迭代结束后重新划分所属域。

在正域中,猎物向负域中的优质猎物学习,同时结合当前猎物反向解进行更新。利用负域中优质猎物更新位置,可以加强个体之间交互作用,提升信息共享程度,有利于提高算法的开发能力。公式如下:

$$\vec{P}_i^c = \vec{P}_i + \vec{P}_r^{\text{obl}} + \vec{P}_n, \quad (10)$$

其中, \vec{P}_n 是负域中随机选择的优质猎物。

最后,计算随机猎物更新前后的适应度值,择优进入下一次迭代,数学模型如下:

$$\vec{P}_i = \begin{cases} \vec{P}_i^c, & f(\vec{P}_i^c) \leq f(\vec{P}_i), \\ \vec{P}_i, & f(\vec{P}_i^c) > f(\vec{P}_i), \end{cases} \quad (11)$$

其中, $f()$ 为适应度函数, $f(P_i^c)$ 和 $f(\vec{P}_i^c)$ 分别表示猎物更新前后的适应度值。

2.4 TWD-MPA 的具体步骤

综上所述,基于三支决策的海洋捕食者算法具体步骤如下:

步骤 1 初始话种群并设置相关参数,如种群数量 N 、搜索空间维度 D 、最大迭代次数 T 等;

步骤 2 计算每个猎物适应度值,创建精英矩阵 E ;

步骤 3 更新种群:

(1)当 $t < T/3$ 时,根据式(1)更新猎物;

(2)当 $T/3 \leq t \leq 2T/3$ 时,分别根据式(2)和(3)更新捕食者和猎物;

(3)当 $t > 2T/3$ 时,根据式(4)更新捕食者。

步骤 4 重新计算每个猎物的适应度值并进行比较替换,更新当前最优个体;

步骤 5 考虑 FADs 效应和涡流的影响,根据式(5)进一步更新猎物;

- 步骤6 基于个体间距离之比将猎物划分为负域、边界域及正域,负域中的猎物根据式(9)进行更新,边界域中的猎物不进行更新,正域中的猎物根据公式(10)进行更新;
- 步骤7 计算每个猎物更新前后的适应度值并根据式(11)择优保存;
- 步骤8 判断算法是否满足结束条件,若满足则终止,输出结果,否则返回步骤2.

3 实验与结果分析

为了验证 TWD-MPA 的寻优性能,本节选取了 10 个基准测试函数进行数值实验,将实验结果与其他 7 种智能优化算法寻优结果进行了比较,并采用两种统计性检验评估方法来进一步验证算法性能.

3.1 测试函数与参数设置

本文选取的基准测试函数包括 5 个单模态函数 $F_1 \sim F_5$ 、3 个多模态函数 $F_6 \sim F_8$ 和 2 个固定维度的多模态函数 $F_9 \sim F_{10}$,具体信息见附录表 S1. 其中单模态函数 $F_1 \sim F_5$ 只有一个全局最优点,用来检测算法的收敛速度、求解精度和局部开发能力;而多模态函数 $F_6 \sim F_{10}$ 有两个及以上局部最优点和一个全局最优点,主要用来检测算法的全局勘探和逃离局部最优的能力;固定维度的多模态函数 $F_9 \sim F_{10}$ 用来展示算法在低维度下的全局勘探能力.

为了验证 TWD-MPA 的有效性及优越性,本文将其与其他基于种群的元启发式算法进行了比较,分别是经典的鲸鱼优化算法 (whale optimization algorithm, WOA)^[13]、灰狼优化算法 (grey wolf optimizer, GWO)^[14]、和近年新提出的孔雀优化算法 (peafowl optimization algorithm, POA)^[15]、蜣螂优化算法 (dung beetle optimizer, DBO)^[16]、人工兔优化算法 (artificial rabbits optimization, ARO)^[17],以及原始海洋捕食者算法 (MPA)、多子群改进的海洋捕食者算法 (multi-subpopulation marine predators algorithm, MSMPA). 为了保证实验的公平性,所有算法的公共参数应保持一致,初始种群设置为 30,最大迭代次数设置为 500. 本文算法 TWD-MPA 的参数参照原算法 MPA 及改进算法 MSMPA 进行设置,与之对比的算法 WOA、GWO、POA、DBO、ARO、MPA、MSMPA 参数依据算法出现的原文献设置,具体信息见附录表 S2 所示. 本文实验环境为 Windows10,64 位操作系统,CPU 为 Intel(R) Core(TM) i7-9700 CPU @ 3.00GHz, 编程软件为 Matlab R2016a.

3.2 实验结果分析

本文将上述 8 种算法在 10 个基准测试函数上分别独立运行 30 次并记录实验结果,包括平均值(Ave)、标准差(Std)、最大值(Max)和最小值(Min)等指标,如附录表 S3 所示. 总体上,TWD-MPA 的寻优性能明显优于其他算法.

对于单模态函数 $F_1 \sim F_5$,TWD-MPA 都取得了最优的求解精度,特别是达到了函数 $F_1 \sim F_4$ 的理论最优值(0). 虽然没有获得函数 F_5 的理论最优值(0),但相比于其他 7 种算法,TWD-MPA 的平均值、标准差、最大值和最小值这 4 项指标均为最优的,寻优性能更好. 与原始 MPA 相比,本文提出的 TWD-MPA 在函数 $F_1 \sim F_4$ 上的寻优精度均提高了 200 多个数量级,说明了步长控制参数 C_F 的调整,使得猎物在迭代后期以较小的步长移动增强了算法局部开发能力,有助于算法快速收敛到全局最优值,从而提高算法的求解精度和局部寻优能力.

对于多模态函数 $F_6 \sim F_{10}$,TWD-MPA 的求解精度和稳定性均优于其他算法,并且在函数 F_6 、 F_8 、 F_9 和 F_{10} 上,均达到理论最优值(0,0,1,0.000 3). 对于函数 F_7 ,虽然本文所提 TWD-MPA 与 DBO、ARO、MSMPA 的结果相似,但其寻优精度仍比原始 MPA 高 4 个数量级. 对于函数 F_6 、 F_8 ,除了 GWO 和 POA,其余算法均获得了理论最优值. 对于函数 F_9 ,TWD-MPA 与 ARO 结果相同,均体现了优越的寻优性能. 对于函数 F_{10} ,虽然 TWD-MPA 与原始 MPA、改进的 MSMPA 均达到理论最优值,但其标准差明显优于这 2 种算法,体现了 TWD-MPA 优越的稳定性. 说明了引进三支学习搜索策略,能有效提高种群多样性,增强个体间信息交流,缓解“过度聚集”现象,使得算法向全局最优点收敛;调整步长控制参数,引入惯性权重系数,使得猎物在迭代前期以较大步长移动增强了算法的全局勘探能力,同时平衡了算法勘探与开发,提高了算法稳定性.

综上所述,本文所提算法在单模态函数和多模态函数上都展现了优越的寻优性能.

3.3 收敛性分析

收敛曲线是由算法第一次迭代到最后一次迭代获得的最优解的适应度值绘制而成,其横坐标表示迭代次数,纵坐标表示算法求解精度.因此,该曲线可以直观地展示算法的寻优精度和收敛速度.图 2 为 TWD-MPA 和其他 7 种算法在 10 个基准函数上的收敛曲线图.

对于单模态函数 $F_1 \sim F_5$, TWD-MPA 均可以在 300 次迭代内收敛,特别是在函数 $F_1 \sim F_4$ 上,TWD-MPA 的收敛速度和寻优精度明显优于其他算法.在函数 F_5 上,TWD-MPA 的收敛速度与其他算法相似,但该算法具有更优越的求解精度.

对于多模态函数 $F_6 \sim F_{10}$,TWD-MPA 均可以在 200 次迭代内收敛.在函数 F_{10} 上,TWD-MPA 具有最快的收敛速度,并且在 100 次迭代内快速收敛到最优值,体现了算法优越的寻优性能.在函数 F_7 上,TWD-MPA 前期的收敛速度与 MSMPA 相似,但后期逐渐优于其他各算法并以最小的迭代次数收敛.在函数 F_6 、 F_8 和 F_9 上,TWD-MPA 与 MSMPA 的收敛速度相差不大,但明显优于其他 6 种算法.

综上所述,与其他算法相比,TWD-MPA 在大多数函数上具有更快的收敛速度和更优的求解精度,充分证明了改进的 TWD-MPA 具有更优越的寻优性能.

3.4 稳定性分析

为了更直观地展示 TWD-MPA 和其他算法的稳定性,本文绘制了箱线图来显示每个函数在 30 次独立实验后的结果分布,如图 3 所示.从图 3 中可以看出, TWD-MPA 算法在所有测试函数上的标准偏差均为 0,没有检测到异常值,并且中位数、最小值与最大值均相等,且与最优解一致.这一结果表明,相比于其他算法,TWD-MPA 在所有测试函数上展现出显著的算法稳定性和卓越的优化性能.

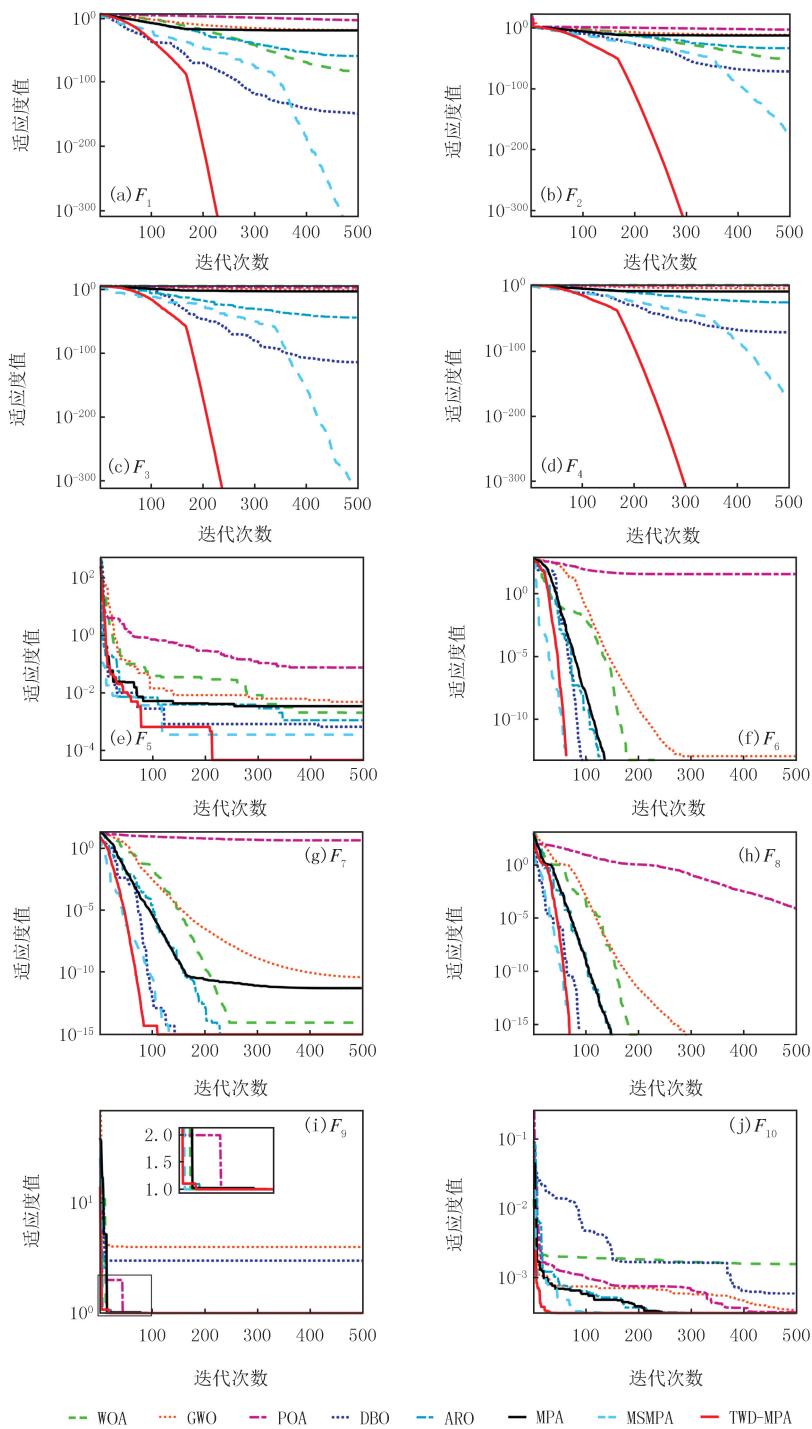


图2 8种算法在基准函数上的收敛曲线图
Fig. 2 Convergence curve of eight algorithms on benchmark function

3.5 统计性分析

为了进一步验证 TWD-MPA 与其他算法在性能上的显著差异,本文对 TWD-MPA 和其他 7 种优化算法的实验结果进行了差异性统计检验。

Wilcoxon 秩和检验是一种流行的非参数统计检验,用于比较 2 个样本数据之间的差异性。本文采用显著性水平为 0.05 的 Wilcoxon 秩和检验将 TWD-MPA 与其他 7 种算法进行两两比较,因此当 p 值小于 0.05 时,表明两种算法之间有显著性差异,否则说明两种算法整体上相当,检验结果如表 1 所示。表中的符号“+/-/=”分别表示 TWD-MPA 的性能优于、劣于、相似于其他对比算法,“NaN”表示两种算法的实验结果一致,不适用于该检验。由表可知,在 10 个基准测试函数上,TWD-MPA 优于 WOA、GWO、POA、DBO、ARO、MPA 和 MSMPA 的函数个数分别为 8、10、10、7、6、8、7。并且除“NaN”外,TWD-MPA 与其他 7 种算法相比的值均小于 0.05,充分证明 TWD-MPA 显著优于其他 7 种算法。

Friedman 检验用于比较多个算法的性能并进行排名。该检验的秩均值越小,表明算法的性能越好。表 2 为 8 种算法在 10 个测试函数上的 Friedman 检验结果,从表 2 中可以看出,WOA、GWO、POA、DBO、ARO、MPA、MSMPA 和 TWD-MPA 的秩均值分别为 5.4967、6.4333、7.0617、3.7450、3.7683、4.8800、2.7100 和 1.9050,其中 TWD-MPA 的秩均值最小,在所有算法的性能等级中排名第一,随后依次是 MSMPA、DBO、ARO、MPA、WOA、GWO 和 POA,算法的排名结果表明 TWD-MPA 显著优于其他算法。

综上所述,与其他 7 种优化算法相比,TWD-MPA 在寻优精度、收敛速度和稳定性等方面有更优秀的表

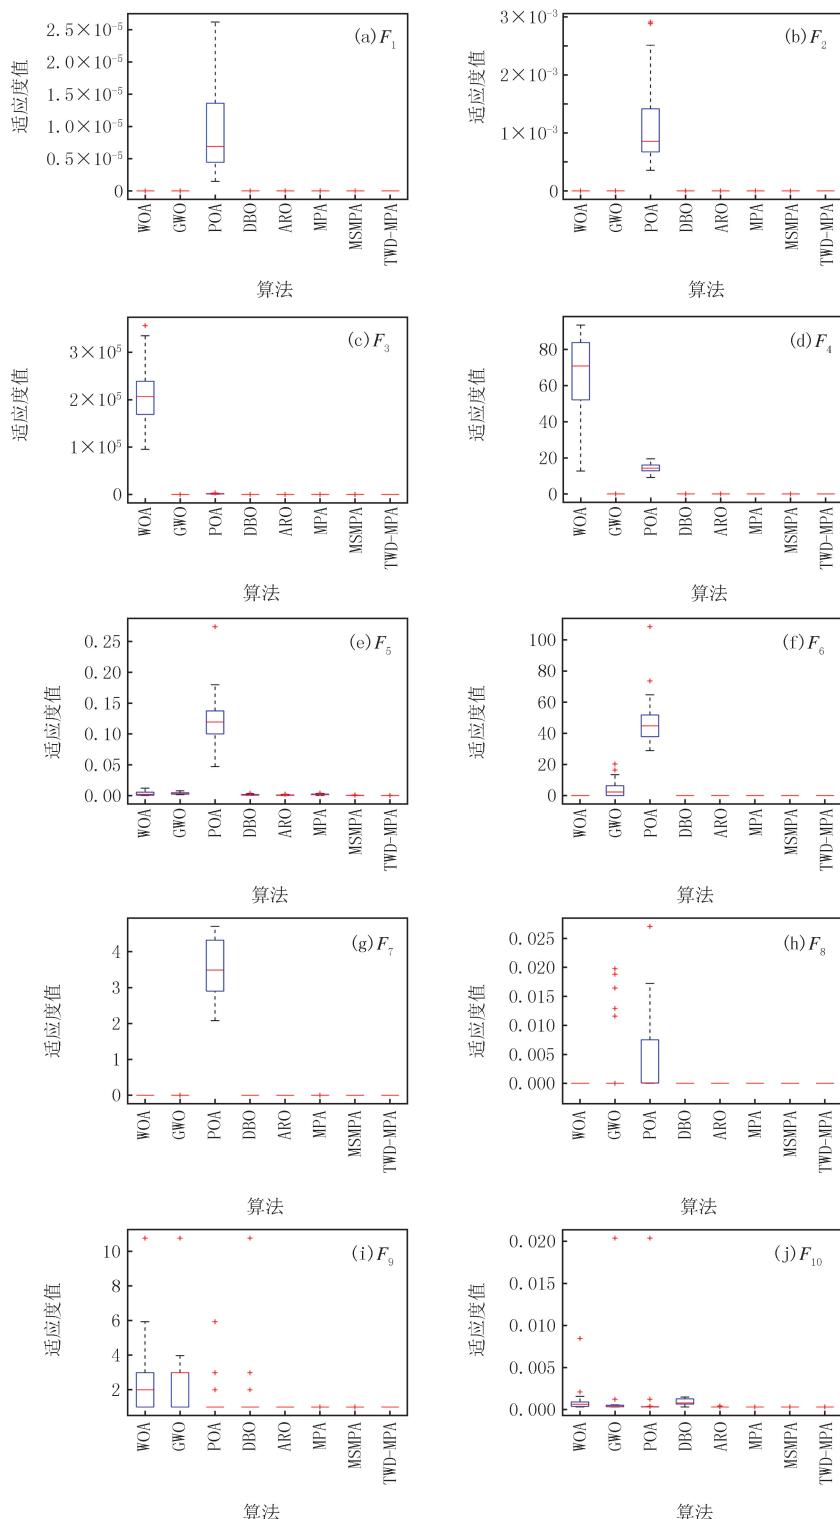


Fig. 3 Boxplot of experimental results for eight algorithms in benchmark functions

现.Wilcoxon 秩和检验中 p 值小于 0.05,Friedman 检验中性能等级排名第 1,都从统计学角度证明了 TWD-MPA 与其他算法存在显著差异性.

表 1 Wilcoxon 秩和检验的统计结果

Tab. 1 Statistical results of the Wilcoxon's rank sum test

函数	TWD-MPA vs.						
	WOA	GWO	POA	DBO	ARO	MPA	MSMPA
F_1	1.21e-12	1.21e-12	1.21e-12	1.21e-12	1.21e-12	1.21e-12	0.0419
F_2	1.21e-12	1.21e-12	1.21e-12	1.21e-12	1.21e-12	1.21e-12	1.21e-12
F_3	1.21e-12	1.21e-12	1.21e-12	1.21e-12	1.21e-12	1.21e-12	8.87e-07
F_4	1.21e-12	1.21e-12	1.21e-12	1.21e-12	1.21e-12	1.21e-12	1.21e-12
F_5	3.47e-10	3.02e-11	3.02e-11	3.02e-11	7.70e-08	3.02e-11	1.29e-06
F_6	NaN	1.21e-12	1.21e-12	NaN	NaN	NaN	NaN
F_7	3.57e-10	1.21e-12	1.21e-12	NaN	NaN	1.21e-12	NaN
F_8	NaN	0.0110	1.21e-12	NaN	NaN	NaN	NaN
F_9	1.21e-12	1.21e-12	1.45e-04	1.45e-04	NaN	4.18e-11	1.03e-12
F_{10}	2.95e-11	2.95e-11	2.95e-11	2.95e-11	2.95e-11	2.95e-11	2.95e-11
+/- =	8/0/2	10/0/0	10/0/0	7/0/3	6/0/4	8/0/2	7/0/3

表 2 Friedman 检验的统计结果

Tab. 2 Statistical results of the Friedman test

函数	p -value	WOA	GWO	POA	DBO	ARO	MPA	MSMPA	TWD-MPA
F_1	1.18e-41	4	6.966 7	8	3	5	6.033 3	1.566 7	1.433 3
F_2	3.17e-41	3.966 7	6.633 3	8	3.033 3	5	6.366 7	2	1
F_3	3.84e-41	8	5.700 0	7	3.033 3	3.966 7	5.300 0	1.800 0	1.200 0
F_4	1.18e-41	7.933 3	6	7.0667	3	4	5	2	1
F_5	2.17e-32	5.066 7	6.233 3	8	4.500 0	3.066 7	5.400 0	2.500 0	1.233 3
F_6	8.73e-42	3.500 0	7	8	3.500 0				
F_7	6.25e-41	4.666 7	7	8	2.583 3	2.583 3	6	2.583 3	2.583 3
F_8	3.55e-34	3.900 0	4.766 7	7.833 3	3.900 0				
F_9	6.84e-30	7.233 3	7.433 3	3.783 3	3.800 0	2.200 0	4.633 3	4.716 7	2.200 0
F_{10}	4.26e-35	6.700 0	6.600 0	4.933 3	7.100 0	4.466 7	2.666 7	2.533 3	1
秩均值	—	5.4967	6.4333	7.0617	3.7450	3.7683	4.8800	2.7100	1.9050
总排名	—	6	7	8	3	4	5	2	1

注:黑体数值为最优值.

4 结语

本文采用三支决策“三分而治”和“延迟决策”的思想来改进海洋捕食者算法.通过将整个猎物种群分为独立的 3 个域,并对每个域中猎物分别采取不同策略进行更新,有效提高了种群多样性,从而避免过早陷入局部最优.种群更新规则中引入步长控制参数策略、惯性权重系数策略,进一步平衡了算法的勘探与开发.基于 10 个基准测试函数的对比实验表明,本文提出的 TWD-MPA 算法在寻优精度和收敛速度等性能指标上具有明显的优势.

附录见电子版(DOI:10.16366/j.cnki.1000-2367.2024.04.12.0002).

参 考 文 献

- tems with Applications, 2020, 152: 113377.
- [2] 张磊, 刘升, 高文欣, 等. 多子群改进的海洋捕食者算法[J]. 微电子学与计算机, 2022, 39(2): 51-59.
ZHANG L, LIU S, GAO W X, et al. Improved marine predators algorithm with multi-subpopulation[J]. Microelectronics & Computer, 2022, 39(2): 51-59.
- [3] HOUSSEIN E H, HASSABALLAH M, IBRAHIM I E, et al. An automatic arrhythmia classification model based on improved Marine Predators Algorithm and Convolutions Neural Networks[J]. Expert Systems with Applications, 2022, 187: 115936.
- [4] FAN Q S, HUANG H S, CHEN Q P, et al. A modified self-adaptive marine predators algorithm: framework and engineering applications [J]. Engineering with Computers, 2022, 38(4): 3269-3294.
- [5] 付华, 刘尚霖, 管智峰, 等. 阶段化改进的海洋捕食者算法及其应用[J]. 控制与决策, 2023, 38(4): 902-910.
FU H, LIU S L, GUAN Z F, et al. Phased-improvement marine predators algorithm and its application[J]. Control and Decision, 2023, 38(4): 902-910.
- [6] SADIQ A S, DEHKORDI A A, MIRJALILI S, et al. Nonlinear marine predator algorithm: a cost-effective optimizer for fair power allocation in NOMA-VLC-B5G networks[J]. Expert Systems with Applications, 2022, 203: 117395.
- [7] HOUSSEIN E H, MAHDY M A, FATHY A, et al. A modified Marine Predator Algorithm based on opposition based learning for tracking the global MPP of shaded PV system[J]. Expert Systems with Applications, 2021, 183: 115253.
- [8] SHAHEEN M A M, YOUSRI D, FATHY A, et al. A novel application of improved marine predators algorithm and particle swarm optimization for solving the ORPD problem[J]. Energies, 2020, 13(21): 5679.
- [9] 龚荣, 谢宁新, 李德伦, 等. 基于邻域粗糙集和海洋捕食者算法的特征选择方法[J]. 微电子学与计算机, 2022, 39(9): 35-45.
GONG R, XIE N X, LI D L, et al. Feature selection method based on neighborhood rough sets and marine predator algorithm[J]. Microelectronics & Computer, 2022, 39(9): 35-45.
- [10] 张贝, 闵华松, 张新明. 改进海洋捕食者算法和插值平滑的机器人路径规划[J]. 计算机应用研究, 2023, 40(7): 2082-2089.
ZHANG B, MIN H S, ZHANG X M. Robot path planning based on improved marine predators algorithm and interpolation smoothing[J]. Application Research of Computers, 2023, 40(7): 2082-2089.
- [11] YAO Y Y. Three-way decisions with probabilistic rough sets[J]. Information Sciences, 2010, 180(3): 341-353.
- [12] 薛占熬, 庞文莉, 姚守倩, 等. 基于前景理论的直觉模糊三支决策模型[J]. 河南师范大学学报(自然科学版), 2020, 48(5): 31-36.
XUE Z A, PANG W L, YAO S Q, et al. The prospect theory based intuitionistic fuzzy three-way decisions model[J]. Journal of Henan Normal University(Natural Science Edition), 2020, 48(5): 31-36.
- [13] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. Advances in Engineering Software, 2016, 95: 51-67.
- [14] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61.
- [15] WANG J B, YANG B, CHEN Y J, et al. Novel Phasianidae inspired peafowl(*Pavo muticus/cristatus*) optimization algorithm: Design, evaluation, and SOFC models parameter estimation[J]. Sustainable Energy Technologies and Assessments, 2022, 50: 101825.
- [16] XUE J K, SHEN B. Dung beetle optimizer: a new meta-heuristic algorithm for global optimization[J]. The Journal of Supercomputing, 2023, 79(7): 7305-7336.
- [17] WANG L Y, CAO Q J, ZHANG Z X, et al. Artificial rabbits optimization: a new bio-inspired meta-heuristic algorithm for solving engineering optimization problems[J]. Engineering Applications of Artificial Intelligence, 2022, 114: 105082.

Marine predator algorithm based on three-way decision

Fang Jing^{1a}, Wan Renxia^{1a,b}, Miao Duoqian^{1b,2}

(1. a. College of Mathematics and Information Science; b. Ningxia Key Laboratory of Intelligent Information and Big Data Processing North Minzu University, Yinchuan 750021, China; 2. Department of Computer Science and Technology, Tongji University, Shanghai 201804, China)

Abstract: In response to the limitations of the traditional marine predator algorithm—specifically its slow convergence speed, low solution accuracy, and susceptibility to local optima, a marine predator algorithm based on three-way decision (TWD-MPA) is proposed in this paper. According to the ratio of the distance between individuals, the prey is classified into positive, negative and boundary regions, with different strategies implemented to update the prey among these three regions. The step size control and inertia weight coefficient strategies are incorporated to balance the algorithm's exploration and exploitation capability. TWD-MPA was subjected to a comparing test against other seven optimization algorithms across 10 benchmark test functions. The results demonstrated TWD-MPA's superior performance in terms of solution accuracy, convergence speed, and stability compared to the other tested algorithms.

Keywords: marine predator algorithm; three-way decision; step size control; inertia weight; boundary region

附 录

表 S1 基准测试函数信息

Tab. S1 Information of benchmark test functions

函数名称	函数模型	维度	定义域	最优解
F_1 :Sphere	$F_1(x) = \sum_{i=1}^n x_i^2$	50	$[-100,100]$	0
F_2 :Schwefel 2.22	$F_2(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	50	$[-10,10]$	0
F_3 :Schwefel 1.2	$F_3(x) = \sum_{i=1}^n (\sum_{j=1}^i x_j)^2$	50	$[-100,100]$	0
F_4 :Schwefel 2.21	$F_4(x) = \max_i \{ x_i , 1 \leq i \leq n \}$	50	$[-100,100]$	0
F_5 :Quartic	$F_5(x) = \sum_{i=1}^n ix_i^4 + \text{random}[0,1)$	50	$[-1.28,1.28]$	0
F_6 :Rastrigin	$F_6(x) = \sum_{i=1}^n [x_i^2 - 10\cos(2\pi x_i) + 10]$	50	$[-5.12,5.12]$	0
F_7 :Ackley	$F_7(x) = -20\exp(-0.2\sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}) - \exp(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)) + 20 + e$	50	$[-32,32]$	0
F_8 :Griewank	$F_8(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos(\frac{x_i}{\sqrt{i}}) + 1$	50	$[-600,600]$	0
F_9 :Foxholes	$F_9(x) = (\frac{1}{5000} + \sum_{j=1}^{25} \frac{1}{j + \sum_{i=1}^2 (x_i - a_{ij})^6})^{-1}$	2	$[65.53,65.53]$	1
F_{10} :Kowalik	$F_{10}(x) = \sum_{i=1}^{11} [a_i - \frac{x_1(b_i^2 + b_i x_2)}{b_i^2 + b_i x_3 + x_4}]^2$	4	$[-5,5]$	0.000 3

表 S2 参数设置

Tab. S2 Parameters settings

算法	参数	算法	参数
WOA	$b = 1$	ARO	r 为 $[0,1]$ 内的随机数
GWO	r_1, r_2 为 $[0,1]$ 内的随机数	MPA	$p = 0.5, F_S = 0.2$
POA	$\tilde{N} = 5, C_v = 0.2$	MSMPA	$p = 0.5, F_S = 0.2$
DBO	$p = 0.2$	TWD-MPA	$p = 0.5, F_S = 0.2$

表 S3 优化算法在 10 个基准函数上的实验结果

Tab. S3 Experimental results of optimization algorithms in ten benchmark functions

函数	标准	WOA	GWO	POA	DBO	ARO	MPA	MSMPA	TWD-MPA
F_1	Ave	6.20E-74	8.04E-20	9.07E-06	6.82E-116	8.98E-57	4.19E-21	0.00E+00	0.00E+00
	Std	2.79E-73	1.16E-19	6.31E-06	3.70E-115	4.59E-56	5.50E-21	0.00E+00	0.00E+00
	Max	1.51E-72	4.78E-19	2.62E-05	2.03E-114	2.51E-55	2.43E-20	0.00E+00	0.00E+00
	Min	4.57E-85	1.43E-21	1.48E-06	4.71E-166	4.77E-67	9.36E-23	0.00E+00	0.00E+00
F_2	Ave	2.55E-49	2.44E-12	1.11E-03	2.28E-53	5.44E-32	2.15E-12	9.76E-165	0.00E+00
	Std	9.73E-49	1.29E-12	7.24E-04	1.25E-52	1.31E-31	2.59E-12	0.00E+00	0.00E+00
	Max	5.16E-48	6.28E-12	2.91E-03	6.85E-52	5.59E-31	1.16E-11	2.93E-163	0.00E+00
	Min	1.55E-56	7.02E-13	3.55E-04	3.35E-80	1.24E-38	3.43E-14	5.81E-193	0.00E+00
F_3	Ave	2.06E+05	1.85E-01	1.38E+03	3.13E-25	5.38E-41	5.96E-02	1.48E-285	0.00E+00
	Std	5.75E+04	3.36E-01	6.23E+02	1.71E-24	1.70E-40	1.04E-01	0.00E+00	0.00E+00
	Max	3.56E+05	1.61E+00	3.09E+03	9.39E-24	8.46E-40	3.93E-01	4.43E-284	0.00E+00
	Min	9.52E+04	3.24E-03	4.96E+02	7.30E-153	1.02E-56	1.54E-07	0.00E+00	0.00E+00
F_4	Ave	6.32E+01	5.00E-04	1.43E+01	3.13E-50	9.31E-23	2.71E-08	1.92E-157	0.00E+00
	Std	2.54E+01	4.10E-04	2.49E+00	1.68E-49	3.22E-22	1.08E-08	9.38E-157	0.00E+00
	Max	9.34E+01	1.60E-03	1.94E+01	9.21E-49	1.70E-21	4.91E-08	5.13E-156	0.00E+00
	Min	1.27E+01	6.48E-05	9.10E+00	7.15E-77	1.09E-28	1.19E-08	1.00E-186	0.00E+00
F_5	Ave	3.32E-03	3.37E-03	1.23E-01	1.28E-03	6.70E-04	1.97E-03	3.23E-04	7.15E-05
	Std	3.50E-03	1.50E-03	4.25E-02	8.10E-04	5.46E-04	9.38E-04	3.20E-04	7.04E-05
	Max	1.20E-02	7.61E-03	2.74E-01	3.86E-03	2.26E-03	3.96E-03	1.12E-03	3.09E-04
	Min	3.86E-05	1.37E-03	4.70E-02	3.85E-04	8.24E-06	4.54E-04	1.35E-05	1.05E-05
F_6	Ave	0.00E+00	4.57E+00	4.75E+01	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
	Std	0.00E+00	5.61E+00	1.58E+01	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
	Max	0.00E+00	2.03E+01	1.08E+02	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
	Min	0.00E+00	1.14E-13	2.89E+01	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
F_7	Ave	4.91E-15	3.90E-11	3.54E+00	8.88E-16	8.88E-16	8.02E-12	8.88E-16	8.88E-16
	Std	2.42E-15	1.98E-11	7.44E-01	0.00E+00	0.00E+00	4.65E-12	0.00E+00	0.00E+00
	Max	7.99E-15	1.13E-10	4.71E+00	8.88E-16	8.88E-16	2.24E-11	8.88E-16	8.88E-16
	Min	8.88E-16	1.41E-11	2.08E+00	8.88E-16	8.88E-16	1.97E-12	8.88E-16	8.88E-16
F_8	Ave	0.00E+00	2.65E-03	5.14E-03	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
	Std	0.00E+00	6.17E-03	8.06E-03	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
	Max	0.00E+00	1.98E-02	2.71E-02	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
	Min	0.00E+00	0.00E+00	1.59E-05	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
F_9	Ave	2.83E+00	3.33E+00	1.49E+00	1.59E+00	9.98E-01	9.98E-01	9.98E-01	9.98E-01
	Std	2.99E+00	3.11E+00	1.32E+00	1.84E+00	0.00E+00	1.51E-16	2.30E-16	0.00E+00
	Max	1.08E+01	1.08E+01	5.93E+00	1.08E+01	9.98E-01	9.98E-01	9.98E-01	9.98E-01
	Min	9.98E-01							
F_{10}	Ave	7.00E-04	5.09E-03	4.25E-04	7.79E-04	3.09E-04	3.07E-04	3.07E-04	3.07E-04
	Std	4.96E-04	8.58E-03	3.28E-04	3.97E-04	4.25E-06	3.44E-15	3.06E-15	2.23E-19
	Max	2.25E-03	2.04E-02	1.59E-03	1.91E-03	3.24E-04	3.07E-04	3.07E-04	3.07E-04
	Min	3.08E-04	3.07E-04						

注: 黑体数值为最优值.