

基于双策略增强SHADE的自适应差分进化算法及其在多阈值图像分割中的应用

程鑫, 陈虹羽, 陈雨涵

温州大学计算机与人工智能学院, 浙江 温州

收稿日期: 2026年3月26日; 录用日期: 2026年4月23日; 发布日期: 2026年4月30日

摘要

多阈值图像分割在医学影像分析中发挥着重要作用, 元启发式算法为其提供了高效的阈值搜索途径。SHADE算法虽具备参数自适应能力, 但仍受限于单一模式参数记忆、固定变异策略以及缺乏主动多样性维护机制等结构性约束。本文提出DSESHADE (Dual-Strategy Enhanced SHADE with Adaptive Diversity Maintenance) 算法, 引入三项改进策略: (1) 双模式自适应参数控制, 依据适应度排名将种群划分为探索组与开采组, 从两套独立参数中心值进行差异化采样并以EWMA方式更新记忆; (2) Softmax自适应双策略变异池, 将DE/current-to-pbest/1与DE/rand/1两种互补策略以Softmax概率动态选择, 配合S型精英比例调度与自适应块交叉; (3) 三级递进式多样性维护系统, 按种群聚集程度依次施加协方差引导扰动、多样性注入和自适应部分重启。该算法与二维Rényi熵及非局部均值二维直方图相结合, 构建面向医学病理图像的多阈值分割模型。在IEEE CEC 2017基准函数集($D=30$)上, DSESHADE以2.241的Friedman平均排名位列8种对比算法首位; 消融实验验证了三项策略缺一不可。在乳腺癌病理图像分割实验中, DSESHADE在PSNR、SSIM、FSIM三项指标的全部6个评测组合中均取得最优排名。

关键词

差分进化, SHADE算法, 自适应参数控制, 多阈值图像分割, 二维Rényi熵

A Dual-Strategy Enhanced SHADE Algorithm with Adaptive Differential Evolution for Multi-Threshold Image Segmentation

Xin Cheng, Hongyu Chen, Yuhan Chen

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

Received: March 26, 2026; accepted: April 23, 2026; published: April 30, 2026

文章引用: 程鑫, 陈虹羽, 陈雨涵. 基于双策略增强 SHADE 的自适应差分进化算法及其在多阈值图像分割中的应用[J]. 计算机科学与应用, 2026, 16(4): 511-522. DOI: 10.12677/csa.2026.164149

Abstract

Multi-threshold image segmentation plays a vital role in medical image analysis, and metaheuristic algorithms offer efficient threshold search pathways for this task. Although SHADE features parameter self-adaptation through its success-history archive, it still suffers from a single-mode parameter memory that treats all individuals identically, reliance on a sole mutation strategy, and the absence of proactive diversity maintenance. This paper proposes the DSESHADE (Dual-Strategy Enhanced SHADE with Adaptive Diversity Maintenance) algorithm, which introduces three targeted improvements: (1) a dual-mode adaptive parameter control that partitions the population into exploration and exploitation groups based on fitness ranking and samples from two independent parameter centres updated via EWMA; (2) a Softmax adaptive dual-strategy mutation pool that probabilistically switches between DE/current-to- p best/1 and DE/rand/1, combined with sigmoid-scheduled elite ratio and adaptive block crossover; and (3) a three-level progressive diversity maintenance system that applies covariance-guided perturbation, periodic diversity injection, and adaptive partial restart with escalating intensity. DSESHADE is integrated with 2D Rényi entropy and non-local means 2D histogram to form a multi-threshold segmentation model for medical pathological images. Experiments on the IEEE CEC 2017 benchmark suite ($D = 30$) show that DSESHADE ranks first among eight compared algorithms with a Friedman mean rank of 2.241. Ablation studies confirm the indispensability of all three strategies. In the breast cancer pathology image segmentation experiment, DSESHADE achieved the best ranking in all six evaluation combinations of the three indicators: PSNR, SSIM, and FSIM.

Keywords

Differential Evolution, SHADE Algorithm, Adaptive Parameter Control, Multi-Threshold Image Segmentation, 2D Rényi Entropy

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

图像分割是计算机视觉与医学影像分析领域的基础性环节，其核心目标是将感兴趣区域从复杂背景中准确分离。围绕这一任务，研究者先后发展出阈值法、区域生长法、聚类法、边缘检测法及深度学习方法等多种技术路线。以 U-Net 为代表的深度分割架构在多项基准上取得了优异指标，但对大规模像素级标注和高算力的依赖制约了其在部分资源受限场景中的推广。相比之下，阈值分割方法凭借原理直观、计算开销低的特点，在标注代价受限或要求快速处理的医学影像分析中仍具不可替代的优势。对于包含多类组织的病理图像，多级阈值分割较双级阈值更能捕捉复杂灰度分布。在优化准则方面，Otsu 最大类间方差[1]与 Kapur 最大 Shannon 熵[2]是两类经典方案；而 Rényi 熵因引入可调参数 α ，在兼顾稀有灰度区域与主体模式时表现出更强的灵活性[3]。然而，多阈值搜索本质上是组合优化问题，候选方案随阈值数呈指数增长，穷举法难以满足实际部署需求。元启发式算法凭借种群协同搜索与无需梯度信息的特性，为多阈值分割提供了高效的求解途径[4] [5]。

差分进化(DE) [6]因实数编码与基于种群差分的变异机制天然适应连续优化问题，已成为多阈值分割中应用最广的进化搜索策略之一[7]。标准 DE 的缩放因子 F 与交叉率 CR 需人工预设，参数敏感问题在高维场景中尤为突出。Tanabe 与 Fukunaga 先后设计了 SHADE [8]与 L-SHADE [9]：前者依托成功历史记

忆库实现 F 和 CR 的在线自适应校准, 后者叠加线性种群缩减策略以压缩冗余评价开销。Aranguren 等 [10] 将 L-SHADE 引入磁共振脑图像分割, 所得分割精度优于多种群智能对比方法。尽管上述工作充分展现了 SHADE 系列在多阈值分割中的竞争力, 但该算法仍存在三方面结构性约束: 其一, 单一模式的参数记忆库对所有个体采用无差别参数采样, 未区分不同适应度排名个体在搜索角色上的差异 [11]; 其二, 整个搜索过程仅依赖 $DE/current\text{-}to\text{-}pbest/1$ 一种变异策略, 缺乏在探索与开采之间实施动态切换的自适应能力; 其三, 标准 SHADE 不具备对种群多样性的主动监测与干预手段, 种群因贪婪选择过早聚集后难以有效恢复 [12]。在目标函数层面, 非局部均值(NLM)二维直方图突破了固定邻域约束, 依据图像块间结构相似度在全图范围内加权平均, 抗噪性能较传统一维直方图有显著改善 [13] [14], 将其与改进元启发式算法联合应用可进一步提升分割质量。

针对上述不足, 本文提出 DSESHADE (Dual-Strategy Enhanced SHADE with Adaptive Diversity Maintenance) 算法, 在保持 SHADE 核心框架完整性的前提下引入三项针对性改进, 并将其与二维 Rényi 熵及非局部均值二维直方图相结合, 构建面向医学病理图像的多阈值分割模型。本文的主要贡献概括如下:

(1) 设计双模式自适应参数控制机制, 依据适应度排名将种群划分为探索组与开采组, 从两套独立的参数中心值出发进行差异化采样, 并以指数加权移动平均方式更新记忆, 实现个体层面的参数适配。

(2) 构建基于 Softmax 函数的自适应双策略变异池, 将 $DE/current\text{-}to\text{-}pbest/1$ 与 $DE/rand/1$ 两种互补策略以概率方式动态选择, 配合 S 型精英比例调度与自适应块交叉, 增强搜索过程中探索与开采的动态平衡能力。

(3) 建立三级递进式多样性维护系统, 按种群聚集程度依次施加协方差引导扰动、周期性多样性注入和自适应部分重启三种力度递增的干预手段, 从机制层面缓解差分进化固有的早熟收敛风险。

本文其余部分组织如下: 第 2 节介绍 SHADE 算法基础与基于二维 Rényi 熵的多阈值图像分割框架; 第 3 节详细阐述 DSESHADE 的三项改进策略及完整算法流程; 第 4 节在 IEEE CEC 2017 基准函数集和乳腺癌病理图像数据集上进行实验验证与分析; 第 5 节总结全文并展望后续研究方向。

2. 相关工作

2.1. SHADE 算法

SHADE (Success-History based Adaptive DE) 算法 [8] 在 JADE [15] 的基础上, 以容量为 H 的环形记忆库替代单步均值估计, 保留多种成功搜索模式, 改善了传统差分进化算法对参数敏感的问题。

SHADE 维护容量为 H 的记忆数组 M_{CR} 和 M_F (初始值为 0.5)。对于个体 \mathbf{x}_i , 随机选取索引 $r_i \in \{1, \dots, H\}$, 分别从高斯和柯西分布采样交叉概率 CR_i 与缩放因子 F_i [8]:

$$CR_i = \text{randn}(M_{CR, r_i}, 0.1^2), \quad F_i = \text{randc}(M_{F, r_i}, 0.1) \quad (1)$$

其中 $CR_i \in [0, 1]$, $F_i \in (0, 1]$ 。变异向量按 “DE/current-to-pbest/1” 策略生成:

$$\mathbf{v}_i = \mathbf{x}_i + F_i \cdot (\mathbf{x}_{pbest} - \mathbf{x}_i) + F_i \cdot (\mathbf{x}_{r_1} - \tilde{\mathbf{x}}_{r_2}) \quad (2)$$

式中 \mathbf{x}_{pbest} 为排名前 $p \cdot NP$ 的精英个体, \mathbf{x}_{r_1} 取自当前种群, $\tilde{\mathbf{x}}_{r_2}$ 取自种群与外部存档 \mathbf{A} 的并集。存档 \mathbf{A} 收集被淘汰的历史个体以增加方向信息。

每代结束后, 算法将成功替换的参数收集至集合 S_{CR} 和 S_F 并记录适应度改善量 Δf_j 。随后以权重 $w_j = \Delta f_j / \sum \Delta f$ 计算加权 Lehmer 均值更新记忆库 [8]:

$$M_{F, k} \leftarrow \frac{\sum_j w_j \cdot F_j^2}{\sum_j w_j \cdot F_j}, \quad M_{CR, k} \leftarrow \frac{\sum_j w_j \cdot CR_j^2}{\sum_j w_j \cdot CR_j} \quad (3)$$

加权 Lehmer 均值偏向较大的成功参数, 有利于保持大步长探索。尽管 SHADE 性能优越, 但在应用中仍存在不足: (1) 单一记忆库未区分探索与开采等搜索角色; (2) 单一变异策略难以在探索与开发间动态切换; (3) 缺乏种群多样性的主动监测与恢复机制, 易导致过早收敛[12]。

2.2. 基于二维 Rényi 熵的多阈值图像分割

多阈值图像分割的最优阈值搜索可视为组合优化问题。为克服一维直方图忽略空间关联的缺陷, 利用非局部均值(NLM)滤波构建二维直方图。以原始灰度值 $A(x, y)$ 与过滤值 $G(x, y)$ 构成有序对, 归一化后得到混合空间结构信息的 NLM 二维直方图 $Q(i, j)$ [14] [16]。

基于 $Q(i, j)$, 采用 α 阶 Rényi 熵[17]作为分割准则函数。设 $n-1$ 个阈值将直方图划分为 n 个子区域 $\{Y_1, \dots, Y_n\}$, 各子区域概率质量记为 W_k , 总熵定义为:

$$R_{\text{total}}^{\alpha} = \sum_{k=1}^n \frac{1}{1-\alpha} \ln \left(\sum_{(i,j) \in Y_k} \left(\frac{Q(i,j)}{W_k} \right)^{\alpha} + \epsilon \right) \quad (4)$$

其中取 $\alpha = 0.5$, ϵ 为极小常数避免数值异常。最优分割即搜索使 $R_{\text{total}}^{0.5}$ 极大化的阈值组合:

$$\mathbf{T}^* = \arg \max_{\mathbf{T}} R_{\text{total}}^{0.5} (T_1, T_2, \dots, T_{n-1}), \quad 0 \leq T_1 < T_2 < \dots < T_{n-1} \leq L-1 \quad (5)$$

随着阈值数增加, 候选解数目呈指数级扩张。在元启发式框架下, 个体位置向量被直接编码为一组候选阈值, 适应度即为对应 $R_{\text{total}}^{0.5}$ 值, 通过迭代搜索逼近最优配置 \mathbf{T}^* 。

3. DSESHADE 算法

SHADE 在处理高维多阈值优化时仍存在单一参数记忆库无差别采样、依赖单一变异策略以及缺乏多样性主动维护等约束。本节依次介绍 DSESHADE 的三项改进策略及算法整体流程。

3.1. 双模式自适应参数控制

受差异化参数分配思路启发[11] [18], DSESHADE 将 SHADE 的单一记忆结构替换为双模式参数记忆机制。依据适应度排名将种群分为开采组与探索组, 从两套独立参数中心出发采样以区分个体的搜索角色。

具体地, 设定两组参数中心值: 探索模式 $M_F^{\text{exp}} = 0.6$, $M_{CR}^{\text{exp}} = 0.85$; 开采模式 $M_F^{\text{ext}} = 0.35$, $M_{CR}^{\text{ext}} = 0.25$ 。个体 \mathbf{x}_i 排序后按排名分配模式:

$$\text{mode}(i) = \begin{cases} \text{exploit}, & \text{若 } \text{rank}(i) \leq NP/2 \\ \text{explore}, & \text{若 } \text{rank}(i) > NP/2 \end{cases} \quad (6)$$

缩放因子 F_i 与交叉概率 CR_i 分别采样自柯西与高斯分布:

$$F_i = \text{clip} \left(M_F^{\text{mode}(i)} + 0.1 \cdot \tan(\pi(\text{rand} - 0.5)), 0.3, 0.95 \right) \quad (7)$$

$$CR_i = \text{clip} \left(M_{CR}^{\text{mode}(i)} + 0.1 \cdot \mathcal{N}(0, 1), 0.1, 0.95 \right) \quad (8)$$

双模式记忆更新采用平方根映射替代线性权重计算:

$$w_k = \frac{\sqrt{\Delta f_k}}{\sum_{j=1}^{|\mathcal{S}|} \sqrt{\Delta f_j} + \epsilon} \quad (9)$$

式中 $|\mathcal{S}|$ 为成功参数个数。随后使用加权均值并结合指数加权移动平均(EWMA)同步更新双模式中心值:

$$\begin{aligned} M_F^{mode} &\leftarrow \lambda \cdot M_F^{mode} + (1-\lambda) \cdot \text{mean}_{wL}(S_F) \\ M_{CR}^{mode} &\leftarrow \lambda \cdot M_{CR}^{mode} + (1-\lambda) \cdot \text{mean}_{wA}(S_{CR}) \end{aligned} \quad (10)$$

平滑因子 $\lambda = 0.88$ 。

3.2. Softmax 自适应双策略变异池

标准 SHADE 固定的单一变异策略限制了探索与开采动态调节。DSESHADE 构建含两种互补策略的变异池，并借助 Softmax 函数依历史成功率动态调整选择概率。

策略 1: DE/current-to-pbest/1

$$\mathbf{v}_i = \mathbf{x}_i + F_i \cdot (\mathbf{x}_{pbest} - \mathbf{x}_i) + F_i \cdot (\mathbf{x}_{r_1} - \mathbf{x}_{r_2}) \quad (11)$$

精英比例 p 随进度自适应递增:

$$p = 0.05 + 0.25 \cdot (1 - e^{-5 \cdot progress}) \quad (12)$$

\mathbf{x}_{r_2} 来源概率随种群实时多样性变化，从种群或外部存档选取:

$$p_{archive} = 0.3 + 0.4 \cdot \left(1 - \frac{D_{current}}{D_{init} + \epsilon}\right) \quad (13)$$

策略 2: DE/rand/1 [6]

$$\mathbf{v}_i = \mathbf{x}_a + F_i \cdot (\mathbf{x}_b - \mathbf{x}_c) \quad (14)$$

$\mathbf{x}_a, \mathbf{x}_b, \mathbf{x}_c$ 为互异随机个体。

策略选择与边界处理。记录策略使用与成功次数得出成功率 sr_k ，经 Softmax 转换为概率:

$$P_{pbest} = \text{clip} \left(\frac{e^{sr_1 - \max(sr_1, sr_2)}}{\sum_{k=1}^2 e^{sr_k - \max(sr_1, sr_2)}}, 0.4, 0.8 \right) \quad (15)$$

以自适应块交叉替代二项式交叉: 取随机维度周边连续块，大小随迭代由 $0.5D$ 缩减至 $0.1D$ 。越界分量采用 0.85 衰减因子反射结合截断兜底修正。

3.3. 三级递进式多样性维护

针对差分进化收缩趋势的不可逆性[12]，DSESHADE 构建三级递进式多样性维护机制，共享归一化种群直径 D_{norm} 为度量:

$$D_{norm} = \frac{D_{current}}{\|\mathbf{ub} - \mathbf{lb}\| \cdot \sqrt{D}} \quad (16)$$

第一级: 协方差引导扰动。搜索中期且 $D_{norm} > 0.06$ 时, 每 30 代沿协方差矩阵 \mathbf{C} 主方向轻微扰动[19]:

$$\mathbf{v}_i \leftarrow \mathbf{v}_i + \alpha \cdot \boldsymbol{\delta}, \boldsymbol{\delta} \sim \mathcal{N}(\mathbf{0}, \mathbf{C}) \quad (17)$$

第二级: 周期性多样性注入。当 $D_{norm} < 0.05$ 或归一化方差 $\sigma_{norm} < 10^{-5}$ 触发。定期替换最差的 10% 个体: 80% 分层重新初始化, 20% 依赖精英附近高斯扰动。

第三级: 自适应部分重启。连续无改善且 $D_{norm} < 0.03$, 重启保留最优的 $\lceil retention \cdot NP \rceil$ 个个体并重置存档:

$$retention = \max(0.15, 0.35 - 0.05 \cdot restart_count) \quad (18)$$

重启同时执行参数记忆部分重置并清理存档。表 1 汇总了三级机制的触发条件与干预力度。

Table 1. Summary of three-level diversity maintenance mechanism in DSESHADE
表 1. DSESHADE 三级多样性维护机制汇总

Brown 级别	触发条件	检查频率	干预力度	作用
协方差扰动	$D_{norm} > 0.06$, 中期	每 30 代	轻微	沿种群主方向微调
多样性注入	$D_{norm} < 0.05$ 或 $\sigma_{norm} < 10^{-5}$	每 15 代	中等(10%替换)	补充空间多样性
部分重启	停滞 + $D_{norm} < 0.03$	每 30 代	强力(65%~85%重置)	搜索方向重置

3.4. 算法流程与复杂度分析

DSESHADE 在 SHADE 基础上引入反向学习(OBL) [20]改善初始化, 并整合前述三项改进策略。算法 1 给出完整伪代码, \star_1 、 \star_2 、 \star_3 分别标注对应操作。

Algorithm 1 DSESHADE 算法

Require: 种群规模 NP , 维度 D , 最大评价次数 $MaxFEs$, 搜索边界 $[lb, ub]^D$
Ensure: 全局最优解 \mathbf{x}_{best} 及其适应度 f_{best}

- 1: 在 $[lb, ub]^D$ 上均匀随机初始化种群 \mathbf{P} 并评价适应度; $FEs \leftarrow NP$
- 2: **for** $i = 1$ **to** NP **do**
- 3: OBL 增强: $\tilde{\mathbf{x}}_i \leftarrow lb + ub - \mathbf{x}_i$; 若 $f(\tilde{\mathbf{x}}_i) < f(\mathbf{x}_i)$ 则 $\mathbf{x}_i \leftarrow \tilde{\mathbf{x}}_i$
- 4: **end for**
- 5: $FEs \leftarrow FEs + NP$
- 6: \star_1 初始化双模式记忆: $M_F^{exp} \leftarrow 0.6$, $M_{CR}^{exp} \leftarrow 0.85$, $M_F^{ext} \leftarrow 0.35$, $M_{CR}^{ext} \leftarrow 0.25$
- 7: 初始化存档 $\mathbf{A} \leftarrow \emptyset$ (容量 $\lfloor 1.8 \cdot NP \rfloor$), 策略计数 $count_k \leftarrow 1$ ($k=1, 2$)
- 8: **while** $FEs < MaxFEs$ **do**
- 9: $S_F, S_{CR}, \Delta f \leftarrow \emptyset$; $progress \leftarrow FEs/MaxFEs$
- 10: \star_2 按式 (15) 计算策略选择概率 P_{pbest}
- 11: \star_3 按式 (16) 估计归一化多样性 D_{norm}
- 12: **for** $i = 1$ **to** NP **do**
- 13: \star_1 按式 (6) 依排名分配模式 m_i , 按式 (7)、(8) 采样 F_i 、 CR_i
- 14: \star_2 以概率 P_{pbest} 选策略 1 (式 (11)), 否则选策略 2 (式 (14)), 生成 \mathbf{v}_i
- 15: \star_2 两层衰减反射边界处理 \rightarrow 自适应块交叉 \rightarrow 试验向量 \mathbf{u}_i
- 16: \star_3 若满足触发条件, 按式 (17) 对 \mathbf{v}_i 施加协方差扰动
- 17: 评价 $f(\mathbf{u}_i)$; $FEs \leftarrow FEs + 1$
- 18: **if** $f(\mathbf{u}_i) < f(\mathbf{x}_i)$ **then**
- 19: 记录 F_i 、 CR_i 至 S_F 、 S_{CR} ; \mathbf{x}_i 加入 \mathbf{A} ; 更新策略计数
- 20: **end if**
- 21: **if** $f(\mathbf{u}_i) \leq f(\mathbf{x}_i)$ **then**
- 22: $\mathbf{x}_i \leftarrow \mathbf{u}_i$
- 23: **end if**
- 24: **end for**
- 25: \star_1 若 $S_F \neq \emptyset$, 按式 (10) 以 EWMA 更新双模式记忆
- 26: \star_3 若满足触发条件, 执行多样性注入或部分重启 (式 (18))
- 27: **end while**
- 28: **return** \mathbf{x}_{best} , f_{best}

设单次评价开销 C_f , 总代数 G 。单代时间复杂度 $O(NP \log NP + NP \cdot D + NP \cdot C_f)$ 。因多样性维护低频运行不改变渐近复杂度, 总体时间复杂度为 $O\left(G \cdot (NP \log NP + NP \cdot D + NP \cdot C_f)\right)$, 空间复杂度 $O(NP \cdot D + D^2)$, 与标准 SHADE 保持同量级。

在多阈值图像分割任务中, 编码候选阈值组合为个体 \mathbf{T} , 以二维 Rényi 熵 $R_{\text{total}}^{0.5}$ 为适应度函数(式(5))。搜索使其达极大值的最优阈值组合 \mathbf{T}^* 用于像素分割。

4. 实验结果与分析

为验证 DSESHADE 在数值优化和实际图像分割两类任务上的有效性, 本节分别在 IEEE CEC 2017 基准函数集和乳腺癌病理图像数据集上进行系统实验, 并与多种代表性算法进行对比。

4.1. 实验设置

本节在 IEEE CEC 2017 基准函数集[21]上进行全局优化实验($D = 30$), 包含 29 个测试函数(排除不稳定的 F2)。对比算法包括 PSO [22]、MSPSO [23]、CLPSO [24]、DE [6]、SaDE [25]、SHADE [8]和 L-SHADE [9]等 7 种算法。种群规模 $NP = 30$, 最大评价次数 $MaxFEs = 300000$, 独立运行 30 次。采用 Wilcoxon 秩和检验($\alpha = 0.05$)和 Friedman 排名评估性能。DSESHADE 参数设为 $M_F^{exp} = 0.6$, $M_{CR}^{exp} = 0.85$, $M_F^{ext} = 0.35$, $M_{CR}^{ext} = 0.25$, $\lambda = 0.88$, $r_{arc} = 1.8$ 。

4.2. 消融实验

为量化三项改进机制的独立贡献, 构建四组消融变体: DSESHADE_{noS1} 移除双模式参数控制, DSESHADE_{noS2} 移除双策略变异池, DSESHADE_{noS3} 移除多样性维护机制, SHADE 为不含任何改进的基线。表 2 列出各变体的机制组合方式。

Table 2. Mechanism portfolio of ablation study variants

表 2. 消融实验各变体的机制组合方式

Brown 机制	DSESHADE	DSESHADE _{noS1}	DSESHADE _{noS2}	DSESHADE _{noS3}	SHADE
S1: 双模式参数控制	√		√	√	
S2: 双策略变异池	√	√		√	
S3: 多样性维护	√	√	√		

表 3 给出了 $D = 30$ 条件下各变体的 Friedman 平均排名与 Wilcoxon 秩和检验结果。

Table 3. Wilcoxon rank-sum test and Friedman ranking for ablation study at $D = 30$

表 3. 30 维消融实验 Wilcoxon 秩和检验与 Friedman 排名

Brown 指标	DSESHADE	DSESHADE _{noS1}	DSESHADE _{noS2}	DSESHADE _{noS3}	SHADE
+/-/=	~	12/1/16	15/5/9	18/4/7	17/5/7
Mean Rank	2.207	3.207	3.034	3.310	3.172
总排名	1	4	2	5	3

完整 DSESHADE 以 2.207 的平均排名位居首位。从各消融变体观察: 移除 S1 (DSESHADE_{noS1}) 平均排名降至 3.207, 劣于基线 SHADE 的 3.172, 反映出双模式参数分配的基础作用; 移除 S3 后(DSESHADE_{noS3}) 排名降至末位, 在组合函数上排名显著下降, 说明多样性维护对复杂多模态景观的求解不可或缺; 仅含有 S1 与 S3 组合的(DSESHADE_{noS2})排名虽优于 SHADE, 但与完整版间仍存在差距。验证了三项机制缺一不可。

4.3. CEC2017 基准函数测试

表 4 汇总了 DSESHADE 与 7 种对比算法的 Wilcoxon 秩和检验统计量和 Friedman 排名。

DSESHADE 的 Friedman 平均排名为 2.241, 位列首位, 对 PSO、CLPSO 等算法取得显著优势。按函数类型分析, 在复杂景观上表现优异, 优势突出: F22~F28 的全部 7 个组合函数均排名第一, F25 的均值由 SHADE 的 4.53×10^3 降至 2.80×10^3 , 改善幅度达 38.2%。DSESHADE 在 F9 上表现略逊于 L-SHADE, 其双模式参数切换在一定程度上引发了额外波动。

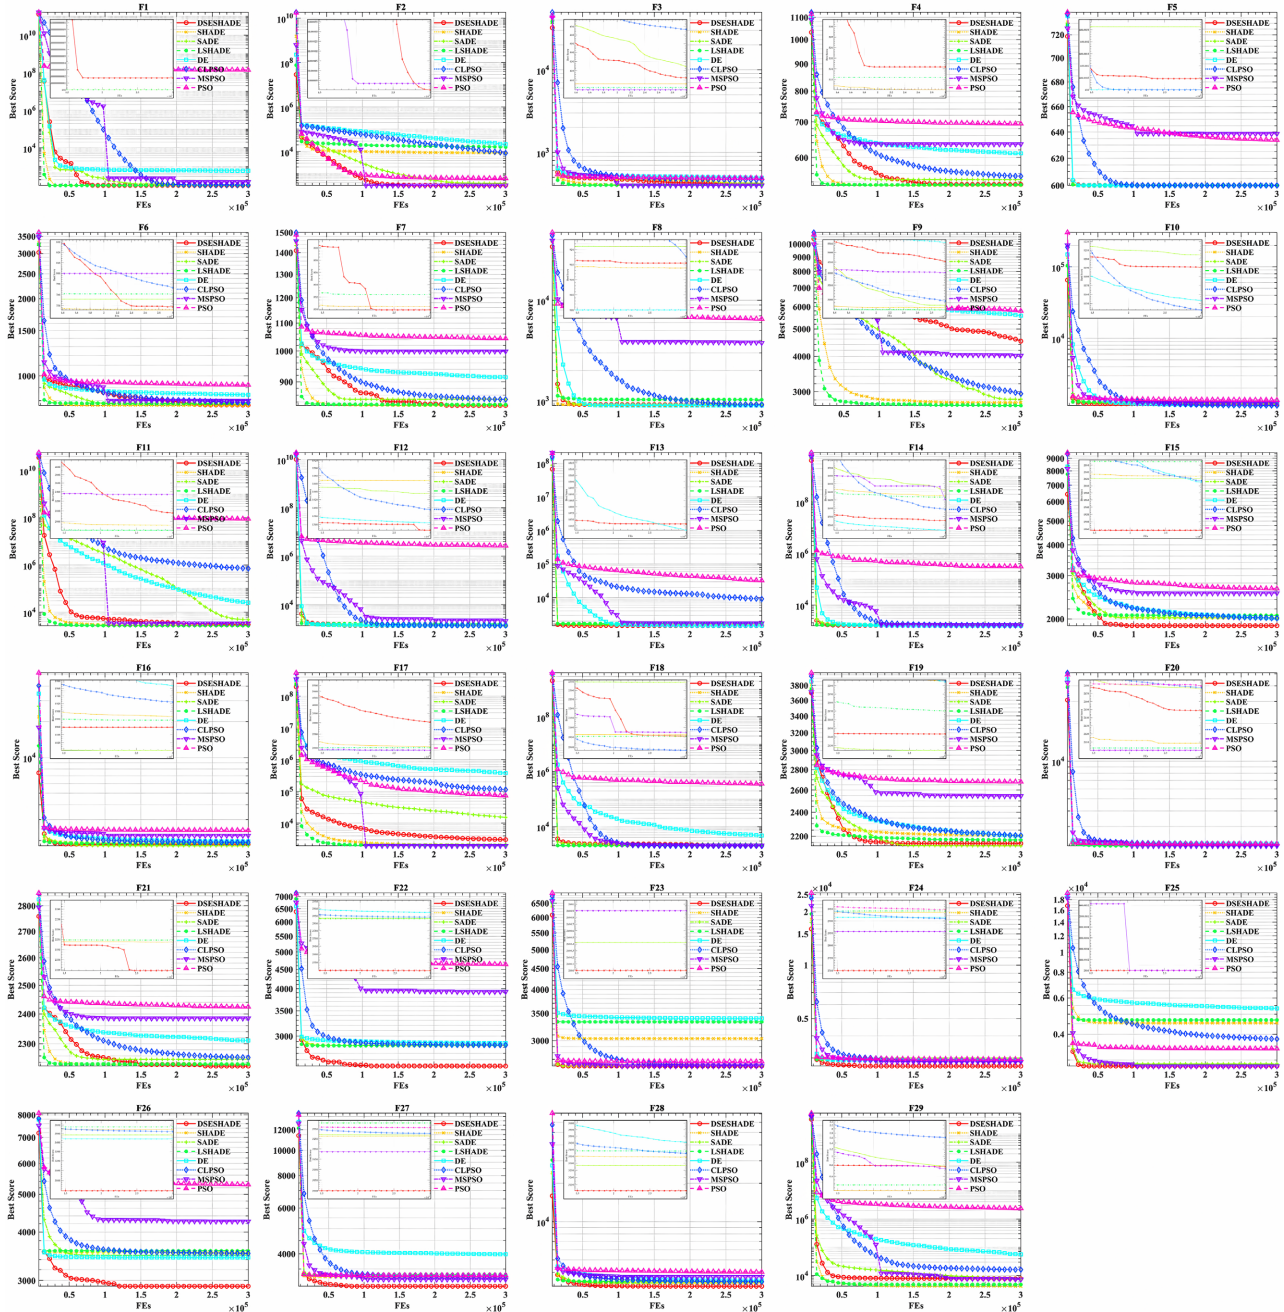


Figure 1. Convergence curves of DSESHADE and comparison algorithms on CEC 2017 ($D = 30$)

图 1. DSESHADE 与对比算法在 CEC 2017 上的收敛曲线($D = 30$)

Table 4. Wilcoxon rank-sum test and Friedman ranking of DSESHADE versus comparison algorithms ($D = 30$)
表 4. DSESHADE 与对比算法的 Wilcoxon 秩和检验及 Friedman 排名($D = 30$)

Brown 指标	DSESHADE	SHADE	SaDE	L-SHADE	DE	CLPSO	MSPSO	PSO
+/-/=	~	17/5/7	17/2/10	17/6/6	23/4/2	24/3/2	23/3/3	29/0/0
Mean Rank	2.241	3.552	4.000	4.103	5.276	4.483	4.931	7.345
总排名	1	2	3	4	7	5	6	8

图 1 收敛过程表明, DSESHADE 在多类函数上迭代末期仍未出现停滞, 反映出 Softmax 双策略在末期保留了方向调节能力; 而 PSO 表现出快速的搜索停滞趋势。在图 2 中, 左侧对应消融实验时的雷达图, DSESHADE 的多边形紧贴中心, 在组合函数段表现尤为突出, S3 在多样性维护和复杂景观处理上作用关键; 右侧为基准侧面的整体雷达图, DSESHADE 面积为各算法中最小。综合验证了 DSESHADE 出色的求解能力与鲁棒性。

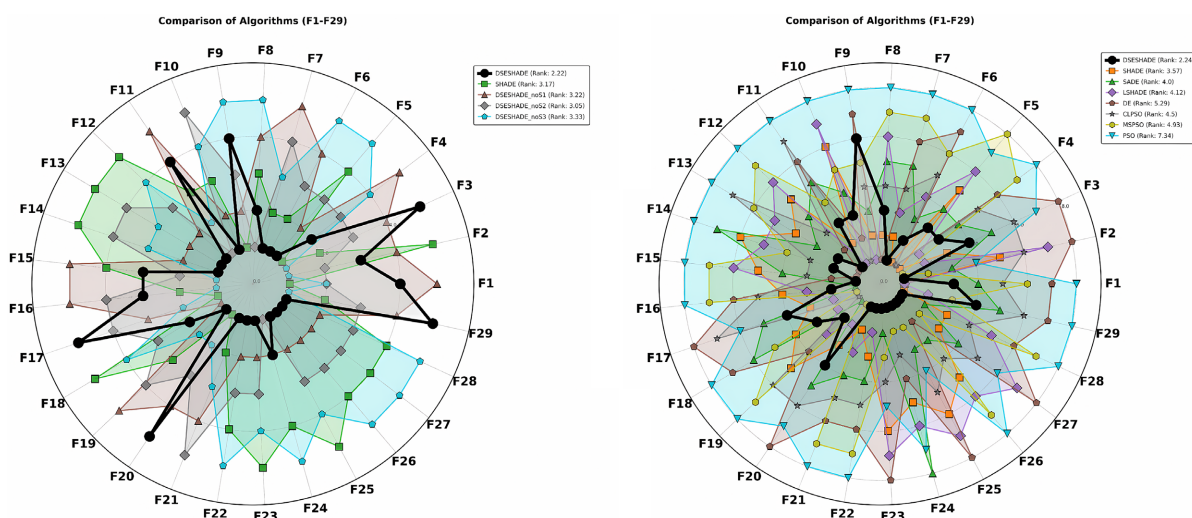


Figure 2. Friedman rank radar chart for ablation study (left) and comparison algorithms (right) at $D = 30$
图 2. 30 维条件下消融实验(左)与对比算法(右)Friedman 排名雷达图

4.4. 医学图像分割实验

实验采用温州医科大学附属第一医院提供的乳腺浸润性导管癌(IDC)病理图像数据集(10 幅 512×512 像素图像), 如图 3 所示。阈值设为 $T = 20, 25$, 参数 $NP = 30$, $t_{\max} = 100$, 独立运行 30 次。分别对比 DE、SSA、CLPSO、IWOA、IGWO、DECLS 和 CLSGMFO 等 7 种算法的分割性能。评价指标涵盖峰值信噪比(PSNR)、结构相似性(SSIM)和特征相似性(FSIM)。

图 3 展示了病理图像呈现出典型的细胞核异型性以及多峰分布的灰度直方图。表 5 汇总了各算法的 Friedman 排名。

表 5 显示, DSESHADE 在各指标与阈值级数下均排名首位。 $T = 20$ 时, PSNR 和 SSIM 排名达理论最优 1.000, 对 CLPSO、IGWO 等取得完全优势。后者受限于固定的搜索策略在 20 维空间难以维持有效的种群覆盖。 $T = 25$ 时 DSESHADE 的排名略有上浮但稳居第一, 体现了改进参数机制和多样性维护带来的高维稳定性。SSA 由于链式跟随机制表现出一定的鲁棒性, 成为次优算法。整体而言, DSESHADE 在像素维度(PSNR)上的领先幅度最为显著。

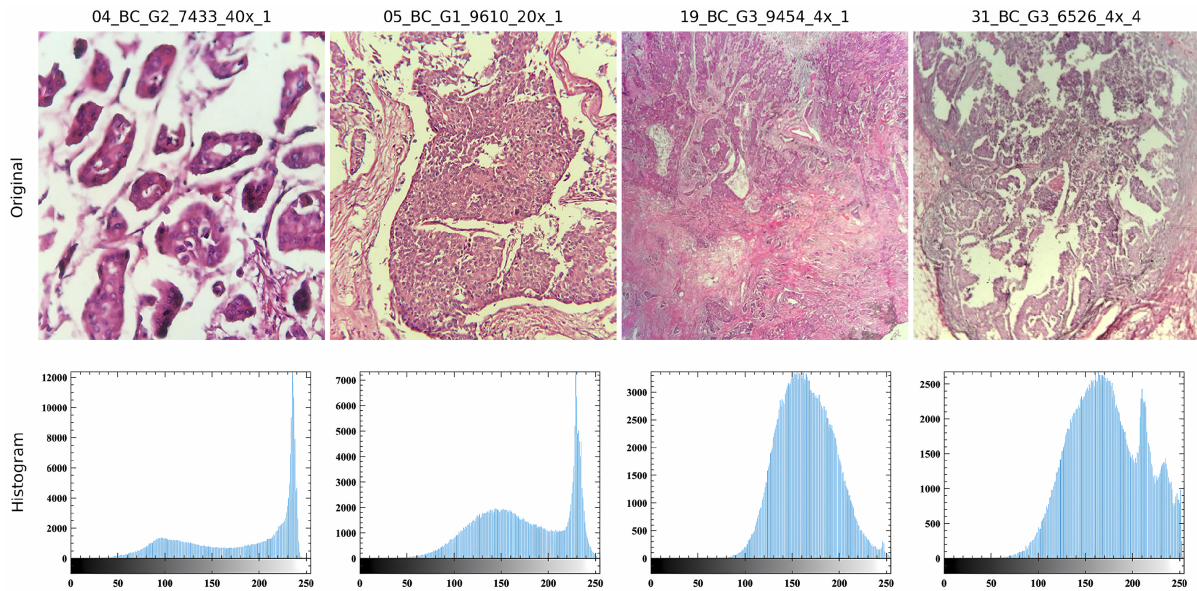


Figure 3. Representative images and grayscale histograms from the breast cancer (IDC) dataset
图 3. 乳腺癌(IDC)数据集代表性图像及灰度直方图

Table 5. Friedman ranking of segmentation metrics on the breast cancer dataset
表 5. 乳腺癌数据集上各算法分割指标 Friedman 排名

Brown 指标	T	DSESHADE	DE	SSA	CLPSO	IWOA	IGWO	DECLS	CLSGMFO
2*PSNR	20	1.000	4.100	2.400	7.400	6.600	7.000	4.500	3.000
	25	2.000	4.300	3.000	7.100	5.700	6.200	4.000	3.700
2*SSIM	20	1.000	4.000	2.700	7.400	6.600	7.000	4.700	2.600
	25	1.500	4.600	2.800	7.200	5.600	6.000	4.300	4.000
2*FSIM	20	1.200	3.400	2.200	7.100	6.700	7.200	4.400	3.800
	25	2.100	4.200	2.200	6.700	5.700	5.900	4.500	4.700

图 4 显示了不同阈值下的分割效果。在 $T = 25$ 下，CLPSO 等算法出现细节丢失或区域混叠，而 DSESHADE 边界清晰，细胞核形态特征保留完好。

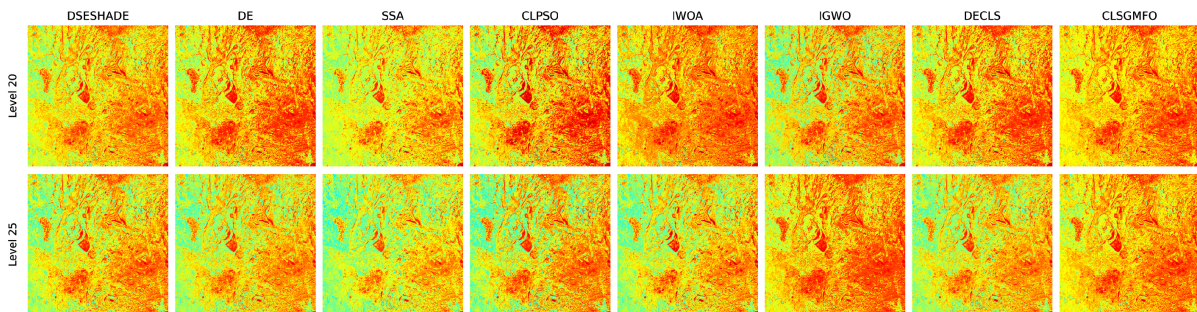


Figure 4. Segmentation results comparison on representative breast cancer images (rows: algorithms, columns: threshold levels)
图 4. 代表性乳腺癌图像分割结果对比(行: 算法, 列: 阈值级数)

4.5. 实验小结

本节不仅在 CEC2017 基准函数集验证了 DSESHADE 作为全局优化算法的优越性，且通过乳腺癌病理图像分割任务表明其在实际高维阈值寻优场景下具有极佳效果和边界保留性能，充分证明了三重改进机制的协同作用。

5. 结论

针对 SHADE 算法在参数控制、变异策略和多样性维护三个维度上的结构性约束，本文提出了 DSESHADE 算法并将其应用于基于二维 Rényi 熵的多阈值图像分割任务。算法的核心改进包括三个方面：(1) 双模式自适应参数控制依据适应度排名将种群划分为探索组与开采组，实现差异化参数采样，使缩放因子 F 和交叉率 CR 的分布更贴合当前搜索阶段的需求；(2) 基于 Softmax 函数的自适应双策略变异池将 $DE/current-to-pbest/1$ 与 $DE/rand/1$ 以概率方式动态选择，利用指数加权移动平均追踪各策略的实时贡献度，强化了探索与开采之间的动态平衡；(3) 三级递进式多样性维护机制依据种群聚集程度分别施加协方差引导扰动、周期性多样性注入和紧急随机重置三种力度递增的干预手段，有效缓解了早熟收敛风险。IEEE CEC 2017 基准函数实验 ($D = 30$) 表明，DSESHADE 以 2.241 的 Friedman 平均排名在 8 种对比算法中位居首位，在组合函数上优势尤为突出。在乳腺癌 IDC 病理图像分割实验中，DSESHADE 在全部 6 个指标×阈值级数组合上均取得最优排名，验证了所提策略在高维多阈值分割场景下的实际应用价值。

未来的研究可从以下方向进一步拓展。首先，当前双模式参数控制的组别划分策略依赖于排名阈值的静态设定，后续可引入强化学习框架实现参数调度策略的在线自适应优化。其次，三级多样性维护机制和 Softmax 策略选择在高阈值级数下带来了一定的计算开销，借助 GPU 并行计算或轻量化替代策略有望缓解这一瓶颈。此外，本文采用的单一二维 Rényi 熵准则对复杂纹理和模糊边界区域的刻画能力有限，将 Rényi 熵与 Tsallis 熵、Otsu 类间方差等准则融合构建多目标优化驱动的分割框架是一个有价值的方向。最后，将所提方法推广至 MRI、CT 等更多成像模态，并探索与深度学习特征提取技术的协同机制，有助于提升方法的泛化能力和临床实用性。

参考文献

- [1] Otsu, N. (1979) A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, **9**, 62-66. <https://doi.org/10.1109/tsmc.1979.4310076>
- [2] Kapur, J.N., Sahoo, P.K. and Wong, A.K.C. (1985) A New Method for Gray-Level Picture Thresholding Using the Entropy of the Histogram. *Computer Vision, Graphics, and Image Processing*, **29**, 273-285. [https://doi.org/10.1016/0734-189x\(85\)90125-2](https://doi.org/10.1016/0734-189x(85)90125-2)
- [3] Sahoo, P.K. and Arora, G. (2004) A Thresholding Method Based on Two-Dimensional Renyi's Entropy. *Pattern Recognition*, **37**, 1149-1161. <https://doi.org/10.1016/j.patcog.2003.10.008>
- [4] Hammouche, K., Diaf, M. and Siarry, P. (2010) A Comparative Study of Various Meta-Heuristic Techniques Applied to the Multilevel Thresholding Problem. *Engineering Applications of Artificial Intelligence*, **23**, 676-688. <https://doi.org/10.1016/j.engappai.2009.09.011>
- [5] Houssein, E.H., Mohamed, G.M., Djenouri, Y., Wazery, Y.M. and Ibrahim, I.A. (2024) Nature Inspired Optimization Algorithms for Medical Image Segmentation: A Comprehensive Review. *Cluster Computing*, **27**, 14745-14766. <https://doi.org/10.1007/s10586-024-04601-5>
- [6] Storn, R. and Price, K. (1997) Differential Evolution—A Simple and Efficient Heuristic for Global Optimization over Continuous Spaces. *Journal of Global Optimization*, **11**, 341-359. <https://doi.org/10.1023/a:1008202821328>
- [7] Bilal, Pant, M., Zaheer, H., Garcia-Hernandez, L. and Abraham, A. (2020) Differential Evolution: A Review of More than Two Decades of Research. *Engineering Applications of Artificial Intelligence*, **90**, Article 103479. <https://doi.org/10.1016/j.engappai.2020.103479>
- [8] Tanabe, R. and Fukunaga, A. (2013) Success-History Based Parameter Adaptation for Differential Evolution. 2013 *IEEE Congress on Evolutionary Computation*, Cancun, 20-23 June 2013, 71-78. <https://doi.org/10.1109/cec.2013.6557555>

- [9] Tanabe, R. and Fukunaga, A.S. (2014) Improving the Search Performance of SHADE Using Linear Population Size Reduction. 2014 *IEEE Congress on Evolutionary Computation (CEC)*, Beijing, 6-11 July 2014, 1658-1665. <https://doi.org/10.1109/cec.2014.6900380>
- [10] Aranguren, I., Valdivia, A., Morales-Castañeda, B., Oliva, D., Abd Elaziz, M. and Perez-Cisneros, M. (2021) Improving the Segmentation of Magnetic Resonance Brain Images Using the LSHADE Optimization Algorithm. *Biomedical Signal Processing and Control*, **64**, Article 102259. <https://doi.org/10.1016/j.bspc.2020.102259>
- [11] Zhang, Y., Chen, G. and Cheng, L. (2023) Improving SHADE with a Linear Reduction P Value and a Random Jumping Strategy. In: Huang, D.S., Premaratne, P., Jin, B., Qu, B., Jo, K.H. and Hussain, A. Eds., *Lecture Notes in Computer Science*, Springer, 47-58. https://doi.org/10.1007/978-981-99-4755-3_5
- [12] Lin, X. and Meng, Z. (2024) An Adaptive Differential Evolution with Enhanced Diversity and Restart Mechanism. *Expert Systems with Applications*, **249**, Article 123634. <https://doi.org/10.1016/j.eswa.2024.123634>
- [13] Mittal, H. and Saraswat, M. (2018) An Optimum Multi-Level Image Thresholding Segmentation Using Non-Local Means 2D Histogram and Exponential Kbest Gravitational Search Algorithm. *Engineering Applications of Artificial Intelligence*, **71**, 226-235. <https://doi.org/10.1016/j.engappai.2018.03.001>
- [14] Hernandez del Rio, A.A., Cuevas, E. and Zaldivar, D. (2020) Multi-Level Image Thresholding Segmentation Using 2D Histogram Non-Local Means and Metaheuristics Algorithms. In: Oliva, D. and Hinojosa, S., Eds., *Studies in Computational Intelligence*, Springer International Publishing, 121-149. https://doi.org/10.1007/978-3-030-40977-7_6
- [15] Zhang, J. and Sanderson, A.C. (2009) JADE: Adaptive Differential Evolution with Optional External Archive. *IEEE Transactions on Evolutionary Computation*, **13**, 945-958. <https://doi.org/10.1109/tevc.2009.2014613>
- [16] Jiang, C., Yang, W., Guo, Y., Wu, F. and Tang, Y. (2018) Nonlocal Means Two Dimensional Histogram-Based Image Segmentation via Minimizing Relative Entropy. *Entropy*, **20**, Article 827. <https://doi.org/10.3390/e20110827>
- [17] Rényi, A. (1961) On Measures of Entropy and Information. *Proceedings of the Fourth Berkeley Symposium on Mathematical Statistics and Probability*, **4**, 547-562.
- [18] Ghosh, A., Das, S., Das, A.K., Senkerik, R., Viktorin, A., Zelinka, I., et al. (2022) Using Spatial Neighborhoods for Parameter Adaptation: An Improved Success History Based Differential Evolution. *Swarm and Evolutionary Computation*, **71**, Article 101057. <https://doi.org/10.1016/j.swevo.2022.101057>
- [19] Hansen, N. (2016) The CMA Evolution Strategy: A Tutorial. arXiv:1604.00772.
- [20] Tizhoosh, H.R. (2005) Opposition-Based Learning: A New Scheme for Machine Intelligence. *International Conference on Computational Intelligence for Modelling, Control and Automation and International Conference on Intelligent Agents, Web Technologies and Internet Commerce (CIMCA-IAWTIC'06)*, Vienna, 28-30 November 2005, 695-701. <https://doi.org/10.1109/cimca.2005.1631345>
- [21] Awad, N.H., Ali, M.Z., Liang, J.J., Qu, B.Y. and Suganthan, P.N. (2016) Problem Definitions and Evaluation Criteria for the CEC 2017 Special Session and Competition on Single Objective Real-Parameter Numerical Optimization. Technical Report, Nanyang Technological University.
- [22] Kennedy, J. and Eberhart, R. (1995) Particle Swarm Optimization. *Proceedings of ICNN'95-International Conference on Neural Networks*, Perth, 27 November 1995-1 December 1995, 1942-1948. <https://doi.org/10.1109/icnn.1995.488968>
- [23] Xia, X., Gui, L. and Zhan, Z. (2018) A Multi-Swarm Particle Swarm Optimization Algorithm Based on Dynamical Topology and Purposeful Detecting. *Applied Soft Computing*, **67**, 126-140. <https://doi.org/10.1016/j.asoc.2018.02.042>
- [24] Liang, J.J., Qin, A.K., Suganthan, P.N. and Baskar, S. (2006) Comprehensive Learning Particle Swarm Optimizer for Global Optimization of Multimodal Functions. *IEEE Transactions on Evolutionary Computation*, **10**, 281-295. <https://doi.org/10.1109/tevc.2005.857610>
- [25] Brest, J., Zumer, V. and Maucec, M.S. (2006) Self-Adaptive Differential Evolution Algorithm in Constrained Real-Parameter Optimization. 2006 *IEEE International Conference on Evolutionary Computation*, Vancouver, 16-21 July 2006, 215-222. <https://doi.org/10.1109/cec.2006.1688311>