

DOI:10.3969/j.issn.1003-5060.2026.03.007

基于改进灰狼优化算法的多阈值图像分割研究

任永强, 汪超, 韩冲

(合肥工业大学 机械工程学院, 安徽 合肥 230009)

摘要:针对传统阈值分割方法在确定最优阈值时容易陷入局部最优、效率不足和对噪声的高敏感性等问题,文章提出一种结合多种策略的灰狼优化(modified strategy integrated grey wolf optimizer, MSI-GWO)算法,并将其用于基于最小对称交叉熵的阈值图像分割。该算法引入改进的 Tent 混沌进行初始化,以增强全局搜索能力并加速优化进程;通过改进控制参数,辅助种群跳出局部极值;同时加入随机游走策略,有效提升对最优解的搜索效率。经过 6 个标准测试函数的验证,MSI-GWO 算法在收敛性能上相较于传统智能优化算法表现更佳。在应用于基于最小对称交叉熵的阈值图像分割时,MSI-GWO 算法在特征相似性指数、结构相似性指数和峰值信噪比等性能指标上,随着阈值数的增加表现出明显的性能提升,验证了该算法在图像分割领域的应用潜力。

关键词:灰狼优化(GWO)算法; Tent 混沌初始化; 随机游走策略; 最小对称交叉熵; 多阈值分割

中图分类号: TP391.9 **文献标志码:** A **文章编号:** 1003-5060(2026)03-0330-07

Research on multi-threshold image segmentation based on improved grey wolf optimization algorithm

REN Yongqiang, WANG Chao, HAN Chong

(School of Mechanical Engineering, Hefei University of Technology, Hefei 230009, China)

Abstract: Addressing the issues commonly encountered in traditional threshold segmentation methods, such as susceptibility to local optima, inefficiency, and high sensitivity to noise, this paper introduces a modified strategy integrated grey wolf optimizer (MSI-GWO), which is applied to threshold image segmentation based on the minimum symmetric cross-entropy. The algorithm incorporates an improved Tent chaos initialization to enhance global search capability and accelerate the optimization process. It modifies control parameters to help the population escape local extrema. Furthermore, the integration of a random walk strategy significantly improves the efficiency of searching for the optimum solution. Verified by six standard test functions, MSI-GWO shows superior convergence performance compared to traditional intelligent optimization algorithms. When applied to threshold image segmentation based on minimum symmetric cross-entropy, MSI-GWO demonstrates a marked improvement in performance metrics, such as feature similarity (FSIM), structural similarity (SSIM), and peak signal-to-noise ratio (PSNR), with an increase in the number of thresholds, confirming the application potential of the algorithm in the field of image segmentation.

Key words: grey wolf optimizer (GWO); Tent chaos initialization; random walk strategy; minimum symmetric cross-entropy; multi-threshold segmentation

收稿日期: 2023-11-21; 修回日期: 2023-12-28

基金项目: 安徽省科技重大专项资助项目(2021d05050002)

作者简介: 任永强(1968—), 男, 浙江东阳人, 博士, 合肥工业大学副教授, 硕士生导师, 通信作者, E-mail: 342474609@qq.com.

0 引言

在图像分割领域中,阈值分割方法因其计算简单、实现容易的优点而被广泛应用于传统图像分割。常见的方法包括 OTSU、Tsallis 熵、Renyi 熵、最小对称交叉熵以及最大熵等。然而,这些方法在确定最优阈值时,往往只依据灰度值而忽视像素的空间信息,导致其容易陷入局部最优解,进而影响图像分割的精度和效率^[1]。

为克服传统阈值分割方法的局限性,学术界已经开展了一系列创新的智能优化算法研究,以期在图像分割中实现最佳阈值的精确选取^[2]。在此背景下,一些研究通过引入先进的策略来增强现有算法。文献[3]在水母搜索算法的基础上引入组合变异策略和动态反向学习策略,提出一种改进的双种群水母搜索(improved double population jellyfish search, IDPJS)算法,该算法有效提升了多阈值图像分割的收敛速度;文献[4]通过多策略融合,提出一种改进的北方苍鹰优化(improved northern goshawk optimization, INGO)算法,增强了原始算法的搜索能力和收敛精度;文献[5]结合伪对立学习和混沌 Tent 映射等策略,提出一种改进的鲸鱼优化算法(improved whale optimization algorithm, IWOA),并应用于 OTSU 多阈值图像分割。此外,文献[6]通过引入非线性收敛因子和布谷鸟搜索机制,提出一种改进的灰狼优化(improved grey wolf optimizer, IGWO)算法,有效避免了算法陷入局部最优。

为提高传统阈值图像分割的精度和效率,本文提出一种结合多策略的改进型灰狼优化(modified strategy integrated grey wolf optimizer, MSI-GWO)算法。该算法采用改进的 Tent 混沌初始化技术以提升全局搜索效果,并通过调整控制参数及集成随机游走策略,有效提升搜索效率。实验对比结果表明,MSI-GWO 算法在收敛性方面优于其他智能优化算法。在应用 MSI-GWO 算法进行基于最小对称交叉熵的多阈值图像分割时,MSI-GWO 算法在结构相似度、峰值信噪比及特征相似度等核心性能指标上展现出显著的改进效果,充分验证了该算法在图像处理领域的应用优势。

1 灰狼优化算法

灰狼优化(grey wolf optimizer, GWO)算法以灰狼的群体行为为核心,通过初始化一个随机

分布的灰狼种群来启动搜索过程。灰狼种群中的个体会根据适应度值的高低,被分类为 α 狼、 β 狼、 δ 狼以及 ω 狼。在优化过程中, α 、 β 、 δ 狼起着引导作用,而 ω 狼则跟随领头狼,共同搜索猎物^[7]。

捕猎过程中,灰狼群体的首要行动是对猎物进行环绕。在这一过程中,必须评估灰狼与目标之间的间隔,并据此调整灰狼的位置,计算公式如下:

$$D = | \mathbf{C}\mathbf{X}_p(t) - \mathbf{X}(t) | \quad (1)$$

$$\mathbf{X}(t+1) = \mathbf{X}_p(t) - \mathbf{A}D \quad (2)$$

其中: t 为当前的迭代次数; $\mathbf{X}_p(t)$ 和 $\mathbf{X}(t)$ 分别表示在第 t 次迭代中猎物和灰狼的位置向量; \mathbf{A} 、 \mathbf{C} 为系数向量,即

$$\mathbf{A} = 2a\mathbf{r}_1 - \mathbf{a} \quad (3)$$

$$\mathbf{C} = 2\mathbf{r}_2 \quad (4)$$

其中: a 为收敛因子,值从 2 到 0 递减; \mathbf{a} 为由常数 a 组成的与 \mathbf{A} 同维的向量; \mathbf{r}_1 、 \mathbf{r}_2 为取值在 $[0, 1]$ 内的随机向量。

在狩猎时,通常由 α 、 β 、 δ 狼来主导,它们根据自身位置估计猎物的位置,而其他灰狼 ω 狼则围绕这些领头狼进行位置更新,间接向猎物靠近。首先需要计算当前灰狼与 α 、 β 、 δ 狼之间的距离,距离计算公式如下:

$$\begin{cases} D_\alpha = | \mathbf{C}_1 \mathbf{X}_\alpha - \mathbf{X} |, \\ D_\beta = | \mathbf{C}_2 \mathbf{X}_\beta - \mathbf{X} |, \\ D_\delta = | \mathbf{C}_3 \mathbf{X}_\delta - \mathbf{X} | \end{cases} \quad (5)$$

其中: \mathbf{X} 为当前灰狼的位置向量; \mathbf{X}_α 、 \mathbf{X}_β 、 \mathbf{X}_δ 分别为 α 、 β 、 δ 狼的位置向量; \mathbf{C}_1 、 \mathbf{C}_2 、 \mathbf{C}_3 为取值在 $[0, 2]$ 内的随机向量。

ω 狼的位置更新公式如下:

$$\begin{cases} \mathbf{X}_1 = | \mathbf{X}_\alpha - \mathbf{A}_1 D_\alpha |, \\ \mathbf{X}_2 = | \mathbf{X}_\beta - \mathbf{A}_2 D_\beta |, \\ \mathbf{X}_3 = | \mathbf{X}_\delta - \mathbf{A}_3 D_\delta | \end{cases} \quad (6)$$

其中: \mathbf{X}_1 、 \mathbf{X}_2 、 \mathbf{X}_3 为 ω 狼分别向 α 、 β 、 δ 狼靠近的向量; \mathbf{A}_1 、 \mathbf{A}_2 、 \mathbf{A}_3 为收敛因子。

结合 α 、 β 、 δ 狼的位置信息来计算下一次迭代中灰狼群体的平均位置,计算公式如下:

$$\mathbf{X}(t+1) = \frac{\mathbf{X}_1 + \mathbf{X}_2 + \mathbf{X}_3}{3} \quad (7)$$

当猎物的位置稳定时,狼群通过最终的进攻行为来完成捕捉过程,即得到最优解。

2 GWO 算法的改进

2.1 改进的 Tent 混沌初始化

在优化过程中,初始化过程对算法的搜索性

能有着决定性影响。常规的随机初始化会导致个体在搜索空间中的分布不均匀,从而增加了算法收敛到全局最优解的难度和时间。

混沌理论提供了一种有效的非线性动态系统初始化手段。在众多混沌模型中,Logistic 映射在搜索空间中能够提供均匀的分布,但在边缘区域的高概率分布不利于其在设计空间的中心区域找到全局最优解。相比之下,Tent 混沌映射以其简洁性和高效的搜索能力,在全局优化中表现得更加出色,尤其是在迭代搜索的速度方面^[8]。

尽管 Tent 映射表现出色,但它也存在周期性较短和周期点不稳定的问题。为解决这些问题,本文在 Tent 混沌映射的基础上,引入了一项随机变量,以避免序列陷入这些不稳定的周期点。改进后的 Tent 混沌映射表达式如下:

$$x_{i+1} = \begin{cases} 2x_i + \frac{\text{rand}(0,1)}{N}, & 0 \leq x < \frac{1}{2}; \\ 2(1-x_i) + \frac{\text{rand}(0,1)}{N}, & \frac{1}{2} \leq x \leq 1 \end{cases} \quad (8)$$

其中: $\text{rand}(0,1)/N$ 为引入的随机变量; N 为粒子的个数。

通过对比 Logistic、Tent 和改进的 Tent 混沌映射在二维区域中的初始分布,得到混沌序列比较图,如图 1 所示。

从图 1 可以看出,改进后的 Tent 混沌映射生成了更为均匀的初始分布。

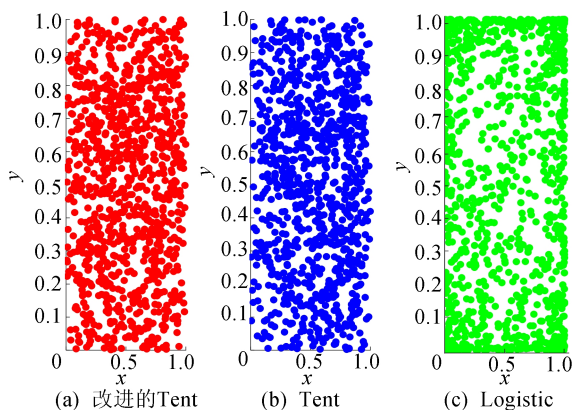


图 1 Logistic、Tent 和改进的 Tent 混沌映射的混沌序列比较图

2.2 改进控制参数 a

在自然界中,灰狼的捕猎行为是一个复杂而动态的过程,不能仅通过简单的线性变化来模拟其在不同阶段的搜索策略。因此,本文根据文献^[9]中提到的函数优化问题,提出采用正弦形式的变化策略来改进控制参数 a ,从而更贴近灰狼的

自然狩猎动态。

正弦形式变化策略可以让参数 a 在迭代过程中产生非线性动态调整,使搜索过程更加多样化,其数学表达式如下:

$$a = 1 + \sin\left(\frac{\pi}{2} + \frac{i}{i_{\max}}\pi\right) \quad (9)$$

其中: i 为当前迭代次数; i_{\max} 为最大迭代次数。

通过对比使用非线性函数与使用常规线性函数计算出的控制参数 a 的变化,得到控制参数比较图,如图 2 所示。

从图 2 可以看出:在迭代初期,非线性函数赋予 a 更大的取值范围,从而为算法提供了更广阔的全局搜索空间;而在迭代后期, a 值逐渐减小,促使算法进行更精细的局部开发,从而加速收敛过程。

该非线性调整策略增强了 GWO 算法的搜索效率,使之更加适应于解决复杂的优化问题。




图 2 控制参数比较图

2.3 改进头狼位置更新方式

2.3.1 α 狼的位置更新

作为群体中地位最高的 α 狼,其位置更新策略应当独立于群体中的其他成员。为增强 α 狼的探索能力并模拟其独立行动的特性,本文采用随机游走策略(莱维飞行机制)来指导 α 狼位置的动态更新。

莱维飞行机制特有的近域探索能力确保 α 狼能够在其当前位置附近密集搜索,这有助于算法快速精确地找到优解。同时,偶尔的长距离跳跃则有助于 α 狼拓宽其搜索范围。通过对比莱维分布、高斯分布和柯西分布,得到三者的分布比较图,如图 3 所示。

从图 3 可以看出,莱维分布巧妙地融合了高斯分布的小步长探索与柯西分布的大步长跳跃特点^[10]。

引入莱维飞行后, α 狼位置的计算公式如下:

$$\mathbf{X}_{\text{best}}(t+1) = \mathbf{X}(t) + \mu \text{Levy}(\lambda) \quad (10)$$

其中, μ 为步长控制因子, 一般取 0.01。随机搜索路径 Levy(λ) 的计算公式如下:

$$|\text{Levy}(\lambda)| = t^{-\lambda}, \quad 1 < \lambda \leq 3 \quad (11)$$

α 狼的位置更新公式如下:

$$\mathbf{X}_\alpha(t+1) = \begin{cases} \mathbf{X}_{\text{best}}(t+1), & \text{其他;} \\ \mathbf{X}_\alpha(t), & f(\mathbf{X}_{\text{best}}(t+1)) > f(\mathbf{X}_\alpha(t)) \end{cases} \quad (12)$$

其中, f 为个体的适应度值。

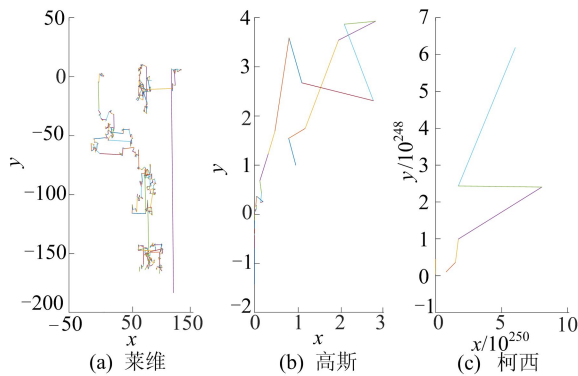


图 3 莱维与高斯、柯西分布比较图

2.3.2 β 狼的位置更新

β 狼将接受 α 狼的领导。本文参考文献[11]的螺旋更新机制, 使 β 狼以螺旋运动接近 α 狼。 β 狼位置更新公式如下:

$$d = |\mathbf{X}_\alpha(t) - \mathbf{X}_\beta(t)| e^{bl} \cos(2\pi l),$$

$$\mathbf{X}_\beta(t+1) = \mathbf{d} + \rho \mathbf{X}_\alpha(t) \quad (13)$$

其中: \mathbf{d} 为常数 d 组成的向量; b 为常数, 定义了对数螺线的形状; l 为 $[-1, 1]$ 中的随机数; ρ 为 $[0, 1]$ 中的随机数。随机数的引入同样是增强 β 狼的探索能力。

2.3.3 δ 狼的位置更新

δ 狼将接受 α 狼和 β 狼的领导, 其位置更新公式如下:

$$\mathbf{X}_\delta(t+1) = \mathbf{D}_\delta - \mathbf{X}_\delta(t) \quad (14)$$

$$\mathbf{D}_\delta = \rho \mathbf{X}_\delta(t) + (1-\rho) \mathbf{X}_\alpha(t) + (1-\rho) \mathbf{X}_\beta(t) \quad (15)$$

2.4 MSI-GWO 算法流程

结合上述改进可得 MSI-GWO 的算法步骤如下:

- 1) 初始化算法参数。
- 2) 根据改进的 Tent 混沌初始化灰狼种群。
- 3) 评估并排序灰狼个体的适应度, 确定 α 狼、 β 狼、 δ 狼的位置, 并结合式(2)、式(7)、式(9)计算灰狼群体的平均适应度。
- 4) 对于适应度低于平均值的灰狼个体, 依照

原始公式更新位置; 否则, 保存当前位置并根据式(12)~(15)进行位置更新。之后比较并保存适应度较高的个体位置。

5) 检查是否满足迭代次数的终止条件, 若满足则输出最优解和对应的适应度值, 否则循环至步骤 3) 继续执行。

3 仿真实验与结果分析

3.1 实验环境设置

本文的实验设置基于 Windows 10 操作系统, 搭载 Intel Core i5 CPU 和 16 GiB RAM; 实验仿真软件采用 MATLAB 2022a, 所用附加工具包包括 Statistics and Machine Learning Toolbox (版本 12.3)、Image Processing Toolbox (版本 11.5) 以及 Deep Learning Toolbox (版本 14.4)。

3.2 MSI-GWO 性能评估

3.2.1 实验设计

为评估性能, 本文选择文献[3-6]提出的优化算法 IDPJS、INGO、IWOA 以及 IGWO 作为对比算法, 在 6 个标准测试函数上迭代 30 次。

测试函数设置见表 1 所列, 各算法参数及其取值见表 2 所列。

表 1 测试函数设置

编号	函数	维度	范围
F1	Generalized Rosenbrock's Function	30	$[-30, 30]$
F2	Step Function	30	$[-100, 100]$
F3	Quartic Function i. e. Noise	30	$[-1.28, 1.28]$
F4	Generalized Rastrigin's Function	30	$[-1.52, 1.52]$
F5	Generalized Penalized Function1	3	$[-50, 50]$
F6	Generalized Penalized Function2	3	$[-50, 50]$

表 2 不同算法的参数值

算法	参数值
IDPJS	$J_r=0.75, D=30$
INGO	$n=1.02 \times 10^{-4}$
IWOA	$a_{\text{start}}=2, \epsilon=3, \omega_{\text{min}}=0.5, \omega_{\text{max}}=0.9, b=1$
IGWO	$a_{\text{initial}}=1, a_{\text{final}}=0, u_b=5.12, l_b=-5.12$
MSI-GWO	$a_{\text{initial}}=2, a_{\text{final}}=0, \beta=1.5$

将上述算法的种群数设置为 50, 最大迭代次数为 1 000, 数据的维度大小为 dim, 数据的上、下边界 u_b, l_b 按照表 1 中的测试函数具体选定。记录各算法的均值、标准差、运行时间和最优解, 以此来比较和评估 MSI-GWO 算法的性能。

3.2.2 测试结果分析

在对比实验中,各算法在测试函数上计算得到的均值、标准差、运行时间和最优解,见表 3 所

列。这些性能指标的结果反映了 MSI-GWO 算法的性能强大,可以通过平均适应度值收敛曲线图更直观地展现出来,如图 4 所示。

表 3 不同算法在 F1~F6 函数上的测试结果

函数	算法	均值	标准差	运行时间	最优解	函数	算法	均值	标准差	运行时间	最优解
F1	MSI-GWO	3.3×10^{-8}	1.2×10^{-7}	0.236 1	3.0×10^{-12}	F4	MSI-GWO	0	0	0.186 3	0
	IDPJS	6.4×10^{-6}	1.1×10^{-5}	0.197 0	7.2×10^{-8}		IDPJS	0	0	0.183 5	0
	INGO	25.937 3	0.822 0	0.193 3	24.962 2		INGO	0	0	0.189 1	0
	IWOA	26.493 6	0.444 7	0.177 4	26.059 3		IWOA	3.8×10^{-15}	1.4×10^{-14}	0.159 0	0
	IGWO	28.785 9	0.056 5	1.631 1	28.562 0		IGWO	0	0	1.537 7	0
F2	MSI-GWO	1.1×10^{-20}	3.2×10^{-20}	0.197 4	4.5×10^{-24}	F5	MSI-GWO	1.6×10^{-19}	3.5×10^{-19}	0.625 0	2.8×10^{-23}
	IDPJS	9.6×10^{-12}	1.9×10^{-11}	0.156 3	3.3×10^{-15}		IDPJS	3.4×10^{-13}	6.9×10^{-13}	0.776 0	5.0×10^{-14}
	INGO	2.1×10^{-8}	1.3×10^{-8}	0.195 6	6.4×10^{-9}		INGO	9.2×10^{-9}	4.9×10^{-9}	0.681 6	2.1×10^{-9}
	IWOA	0.431 7	0.356 5	0.153 3	5.1×10^{-6}		IWOA	0.022 8	0.012 6	0.622 0	8.2×10^{-7}
	IGWO	0.721 6	0.162 5	1.179 9	0.366 7		IGWO	0.015 5	0.038 8	1.955 3	0.006 5
F3	MSI-GWO	7.7×10^{-5}	7.0×10^{-5}	0.473 7	5.0×10^{-6}	F6	MSI-GWO	2.9×10^{-18}	8.8×10^{-18}	0.838 1	3.0×10^{-23}
	IDPJS	0.000 2	0.000 1	0.381 7	9.0×10^{-6}		IDPJS	3.7×10^{-12}	9.0×10^{-12}	0.639 5	4.5×10^{-15}
	INGO	0.000 2	0.000 1	0.362 1	8.8×10^{-6}		INGO	0.136 9	0.354 8	0.584 2	3.9×10^{-8}
	IWOA	0.000 6	0.000 3	0.327 5	8.3×10^{-5}		IWOA	0.336 6	0.164 9	0.541 2	0.098 8
	IGWO	7.8×10^{-5}	7.6×10^{-5}	1.351 3	1.9×10^{-6}		IGWO	0.149 1	0.018 8	1.973 8	0.092 2

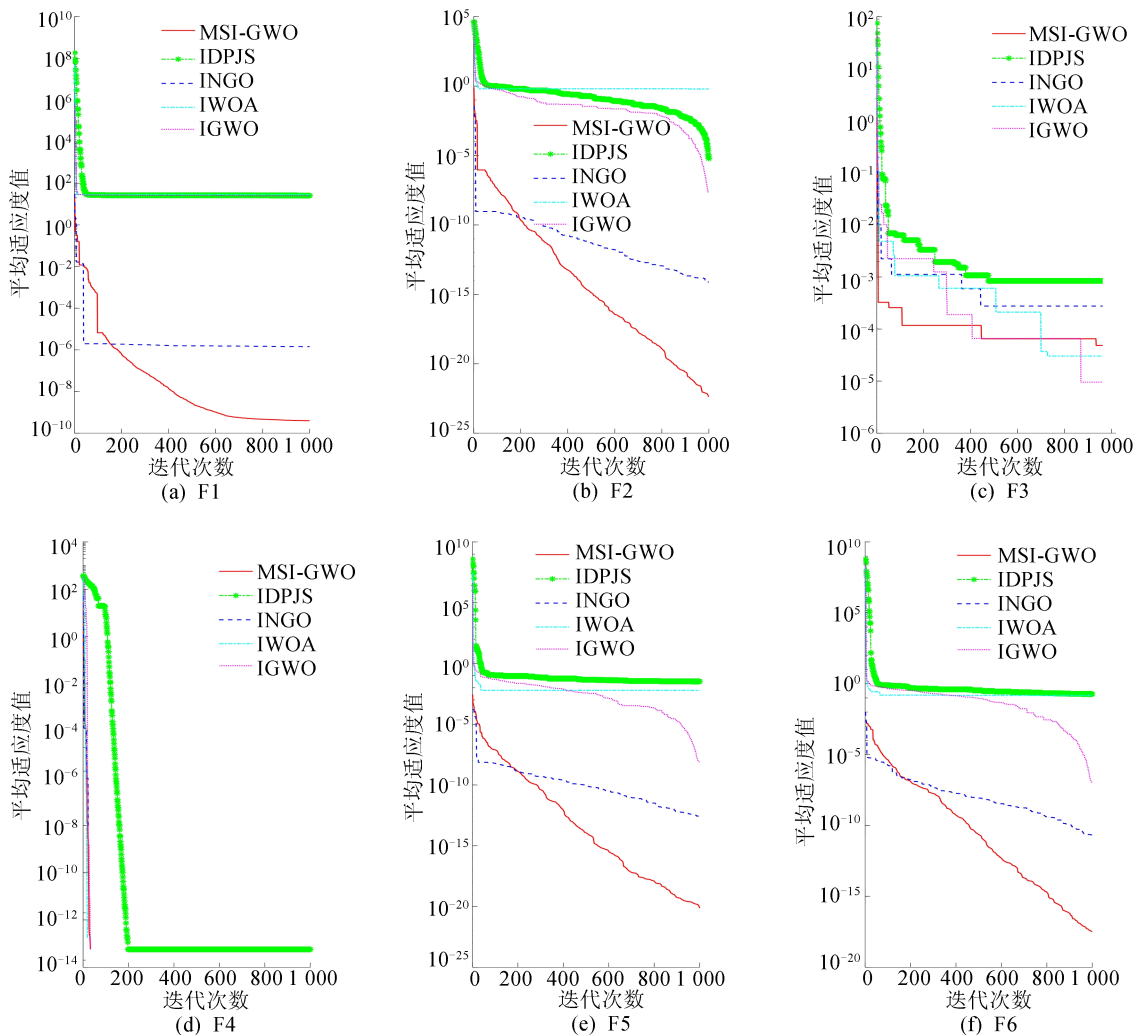


图 4 不同算法的 F1~F6 函数收敛曲线对比

从表 3 可以看出:在 F1 函数上,本文 MSI-GWO 算法的均值和最优解均远小于其他算法,其优势更是达到了数个数量级;在 F2 函数上 MSI-GWO 算法在寻找全局最优解方面表现得非常好;在 F3 函数上,MSI-GWO 算法与其他算法相比,尽管它的最优解不是绝对最小的,但考虑到均值和标准差的结果,仍显示出了很好的稳定性;在 F4 至 F6 函数上,尽管所有算法在最优解上表现出相似的结果(都接近 0),但 MSI-GWO 算法在稳定性方面却更加出色。

总的来说,MSI-GWO 算法在寻找全局最优解和算法稳定性方面显示出优越性,在解决这类优化问题时,MSI-GWO 算法是非常好的选择。

从图 4 可以直观地观察到,MSI-GWO 算法的收敛曲线在接近理论最优解方面展现出更为锐利、直接的趋势。这不仅证明了该算法优越的精度,也展现了其在达到近似最优解过程中的效率。相较于其他算法,MSI-GWO 算法需要的迭代次数更少,这在计算资源有限的情况下显得尤为宝贵。

4 最小对称交叉熵阈值分割原理

最小对称交叉熵是一种常用的图像分割准则,它基于像素分布的差异,通过最小化分割前、后图像信息量差异来选取最优的阈值^[12-13]。熵的计算公式如下:

$$H(t_1, t_2, \dots, t_n) = H_0 + H_1 + \dots + H_n \quad (16)$$

其中, (t_1, t_2, \dots, t_n) 表示分割图像的阈值数。

$$H_{n-1} = \sum_{i=t_{n-1}}^{t_n} h_i \left[i \ln \frac{i}{\mu_{n-1}(t)} + \mu_{n-1}(t) \ln \frac{\mu_{n-1}(t)}{i} \right],$$

$$\mu_{n-1}(t) = \sum_{i=t_{n-1}}^{t_n} \frac{iP_i}{\sum_{i=t_{n-1}}^{t_n} P_i} \quad (17)$$

其中, P_i 为灰度级 i 出现的频率。

本文将图像总熵值最小时的阈值组合表示为 $(t_1^*, t_2^*, \dots, t_n^*)$, 则最小对称交叉熵判断公式如下:

$$t(t_1^*, t_2^*, \dots, t_n^*) = \operatorname{argmin} \sum_{k=0}^n H_k \quad (18)$$

5 最小对称交叉熵阈值图像分割

5.1 实验设置

本文选取灰度级为 256 的 3 张标准测试图像 Lena、cameraman、peppers 以及 1 张工业场景锂电池极耳图像作为多目标分割对象,如图 5 所示。

分割阈值数 K 选取 2、3、4、5 进行分割。

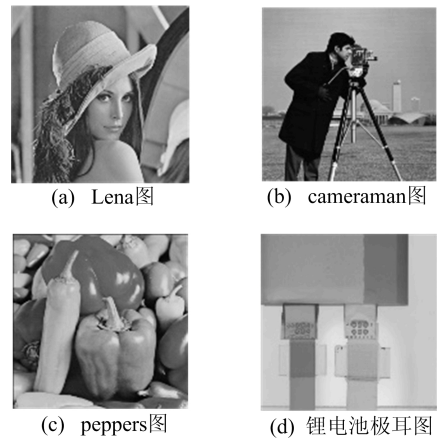


图 5 测试图

5.2 结果分析

使用 MSI-GWO 算法对不同分割阈值数下的图像进行处理,得到相应的效果图,如图 6 所示。

从图 6 可以看出,随着阈值数的增加,图像细节和信息完整性均有所提升。实验表明:MSI-GWO 算法能有效进行多阈值分割,精确划分图像中的不同区域。

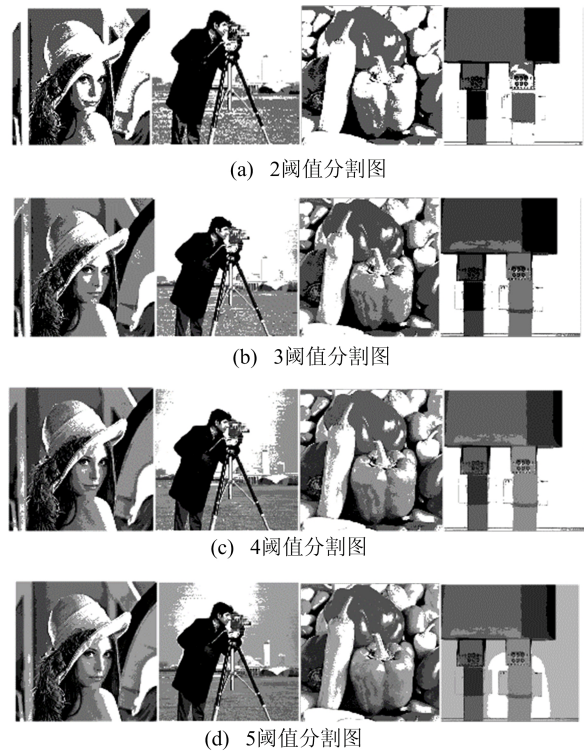


图 6 不同阈值分割结果图

为了更加客观地评估 MSI-GWO 算法,在实验中采用特征相似性指数 (feature similarity,

FSIM)、结构相似性指数(structural similarity, SSIM)和峰值信噪比(peak signal-to-noise ratio, PSNR)作为评价指标,3项指标的统计结果见表4所列。

表4 FSIM、SSIM、PSNR 指标统计结果

图像	评价 指标	阈值数			
		2	3	4	5
Lena	FSIM	0.767 7	0.822 0	0.855 1	0.877 6
	SSIM	0.555 2	0.619 9	0.649 2	0.695 5
	PSNR	15.521 2	17.454 5	18.713 2	20.055 4
cameraman	FSIM	0.758 7	0.816 5	0.854 3	0.881 7
	SSIM	0.611 8	0.661 5	0.689 1	0.709 8
	PSNR	16.166 6	18.588 7	21.347 0	22.867 8
peppers	FSIM	0.752 3	0.808 9	0.850 4	0.885 0
	SSIM	0.585 4	0.607 4	0.668 7	0.704 0
	PSNR	15.444 9	17.693 3	20.190 3	21.744 7
锂电池极耳	FSIM	0.862 5	0.879 6	0.912 5	0.912 8
	SSIM	0.764 7	0.780 3	0.903 4	0.912 4
	PSNR	13.901 3	14.735 1	20.711 0	21.227 1

观察表4中数据发现:MSI-GWO算法在处理标准测试图像时,随着阈值数的增加,FSIM、SSIM和PSNR的数值也在增加;在处理锂电池极耳图像时,算法在较高阈值下表现更加出色,有效提升了图像质量并保持了特征相似性和结构完整性。

这些结果表明,MSI-GWO算法在处理图像时,能够随着更细致的分割保留更多的图像细节和结构信息,尤其在处理复杂图像时表现显著。

6 结 论

针对传统阈值分割方法容易陷入局部最优、效率低下等问题,本文提出一种结合多策略的改进型灰狼优化 MSI-GWO 算法用于最小对称交叉熵的多阈值图像分割。通过引入 Tent 混沌初始化和优化控制参数,结合随机游走策略,MSI-GWO 算法的全局搜索能力和局部精度得到提高。实验结果表明:MSI-GWO 算法在收敛性能方面表现出高精度、高稳定性以及高效率;在多阈值分割中,MSI-GWO 算法在 FISM、SSIM、

PSNR 等指标上同样表现卓越。

未来工作可进一步扩大 MSI-GWO 算法的应用范围,例如引入人工蜂群中食物源的概念,以应对算法的进化停滞问题,预期可进一步提高算法的整体效能。

[参 考 文 献]

- [1] 刘硕. 阈值分割技术发展现状综述[J]. 科技创新与应用, 2020(24):129-130.
- [2] 史春天,曾艳阳,侯守明. 群体智能算法在图像分割中的应用综述[J]. 计算机工程与应用,2021,57(8):36-47.
- [3] 王秋萍,李晓丹,戴芳,等. 基于改进双种群水母搜索算法的多阈值图像分割[J]. 纯粹数学与应用数学,2022,38(3):392-402.
- [4] 付雪,朱良宽,黄建平,等. 基于改进北方苍鹰优化算法的多阈值图像分割[J]. 计算机工程,2023,49(7):232-241.
- [5] 王冠,张亚宁. 改进鲸鱼算法优化 Ostu 多阈值图像分割[J]. 佳木斯大学学报(自然科学版),2023,41(3):174-177.
- [6] 陈建东,聂斌,雷银香. 一种改进灰狼优化算法[J]. 现代信息科技,2023(19):94-98.
- [7] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer [J]. Advances in engineering software, 2014, 69: 46-61.
- [8] 张娜,赵泽丹,包晓安,等. 基于改进的 Tent 混沌万有引力搜索算法[J]. 控制与决策,2020,35(4):893-900.
- [9] WEN L, JIAN J J, XI M L, et al. Inspired grey wolf optimizer for solving large-scale function optimization problems [J]. Applied Mathematical Modelling, 2018, 60: 112-126.
- [10] 梁静. 融合自适应权重与 Levy 飞行的拉丁超立方体海鸥优化算法及应用[J]. 智能计算机与应用, 2022, 12(11): 216-223.
- [11] MIRJALILI S, LEWIS A. The whale optimization algorithm [J]. Advances in Engineering Software, 2016, 95: 51-67.
- [12] KULLBACK S, LEIBLER R A. On information and sufficiency [J]. The Annals of Mathematical Statistics, 1951, 22(1): 79-86.
- [13] 吴一全,张晓杰,吴诗嫻. 2 维对称交叉熵图像阈值分割 [J]. 中国图象图形学报, 2011, 16(8): 1393-1401.

(责任编辑 胡亚敏)