

DOI:10.19651/j.cnki.emt.2107707

基于麻雀算法优化的 OSTU 分割算法^{*}

李 鹏^{1,2,3} 丁倩雯^{1,2}

(1.南京信息工程大学 江苏省气象探测与信息处理重点实验室 南京 210044; 2.南京信息工程大学 江苏省大气环境与装备技术协同创新中心 南京 210044; 3.南京信息工程大学 滨江学院 无锡 214105)

摘 要: 针对传统最大类间差法(OSTU)在分割图像时计算量大、时间效率低的缺点,提出一种基于 Singer 混沌映射和随机游走策略的麻雀优化的 OSTU 分割方法(SRWSSA)。首先,利用 Singer 混沌映射改进初始化麻雀种群,增加初始麻雀种群的多样性,提高全局搜索能力;其次,采用随机游走策略对更新后的最优麻雀进行扰动变异,进一步增加种群多样性,增强局部搜索能力;最后,使用提出的优化算法对标准图像进行二维 OSTU 分割,得到最优阈值分割图像。结果表明,所提出的 SRWSSA 算法在寻优能力和迭代时间上均得到了明显改善,迭代次数较 PSO-OSTU、SSA-OSTU 分别减少了 83.3%、76%,图像峰值信噪比分别提高了 8.2%、11.3%,运行时间上也有所提高,具有一定的可行性。

关键词: 麻雀搜索算法;图像分割;OSTU 算法;群智能优化算法

中图分类号: TP391.4 **文献标识码:** A **国家标准学科分类代码:** 510.1050

OSTU segmentation algorithm based on sparrow algorithm optimization

Li Peng^{1,2,3} Ding Qianwen^{1,2}

(1. Jiangsu Key Laboratory of Meteorological Observation and Information Processing, Nanjing University of Information Science and Technology, Nanjing 210044, China; 2. Jiangsu Collaborative Innovation Center on Atmospheric Environment and Equipment Technology, Nanjing University of Information Science and Technology, Nanjing 210044, China; 3. Binjiang College, Nanjing University of Information Science and Technology, Wuxi 214105, China)

Abstract: Aiming at the disadvantages of large amount of calculation and low time efficiency of traditional maximum inter class difference method (OSTU) in image segmentation, a sparrow optimized OSTU segmentation method (SRWSSA) based on singer chaotic map and random walk strategy is proposed. Firstly, Singer chaotic map is used to improve the initialization sparrow population, increase the diversity of initialization population and improve the global search ability. Secondly, the random walk strategy is used to perturb and mutate the updated optimal sparrow, so as to further increase the population diversity and enhance the local search ability. Finally, the standard image is segmented by two-dimensional OSTU using the proposed optimization algorithm to obtain the optimal threshold segmentation image. The SRWSSA algorithm proposed has significantly improved the optimization ability and iteration time. Compared with PSO-OSTU and SSA-OSTU, the number of iterations is reduced by 83.3% and 76% respectively. The image peak signal-to-noise ratio is increased by 8.2% and 11.3% respectively, and the running time is also improved. Practice shows that this method is feasible.

Keywords: sparrow search algorithm; image segmentation; OSTU algorithm; swarm intelligence optimization algorithm

0 引 言

图像分割是图像处理的前提,即利用图像处理技术从中提取感兴趣的部分^[1]。最常见的分割依据包括边缘、阈值和区域。其中 OSTU 算法^[2]由于其原理简单、容易实现而在很多方面广泛应用。但其计算复杂,抗噪性能不理想,

对复杂图像的分割效果不够好。

群智能优化算法是根据自然界中的生物运动规律所提出的一种算法,这类算法能在一定范围内寻找最优解,解决了很多参数优化问题。例如,王新等^[3]结合粒子群算法、差分进化算法和 Nelder-Mead 优化算法设计了一种非线性的混合智能算法。凤丽洲等^[4]提出一种基于双重驱动的果蝇

收稿日期:2021-08-26

^{*} 基金项目:江苏省重点研发计划社会发展项目(BE2015692)、江苏省第 11 批六大高峰人才项目(2014-XXRJ-006)资助

优化算法解决了传统智能算法计算复杂度高、参数依赖性强的缺点。

麻雀搜索算法是 Xue 等^[5]于 2020 年提出的,主要受麻雀的觅食行为和反捕食行为的启发,算法新颖,寻优能力强,收敛速度快。但 SSA 在迭代后期也会出现种群多样性减少,陷入局部最优解,以致降低收敛精度。不少学者对其进行了改进: Liu 等^[6]引入混沌策略对算法的总体进行优化;李爱莲等^[7]针对 SSA 在寻优后期出现能力不足、种群多样性丢失等问题,提出了融合正余弦和柯西变异的 SCSSA 方法;张伟康等^[8]提出 Circle 映射和蝴蝶优化算法改进的 SSA 算法;段玉先等^[9]提出一种基于 Sobol 序列和纵横交叉策略的麻雀搜索算法,在收敛速度和求解准确率上均取得优势。

针对以上问题,本文对 SSA 算法提出了改进:在麻雀种群初始化阶段,利用混沌映射,增加麻雀初始种群的多样性,提高全局搜索能力;在麻雀位置更新后,融合随机游走策略,增加最优麻雀的扰动,提高其局部搜索性。

1 SSA

SSA 是模拟麻雀捕食和反捕食行为的一种优化算法,种群成员包括发现者、跟随者和侦察者^[10]。其中发现者寻找食物,决定整个种群的觅食区域和方向;跟随者根据发现者提供的信息觅食。二者身份在一定条件下可以相互转化。同时,侦察者发现危险,并决定是否撤离危险区域。每个阶段,发现者和侦察者在整个种群中分别占比 10%~20%。

将麻雀种群用一个 $n \times d$ 维的矩阵表示如式(1)所示。其中, n 表示麻雀数量, d 表示维数, X_{nd} 表示第 n 只麻雀在第 d 维时的位置信息。

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1d} \\ x_{21} & x_{22} & \cdots & x_{2d} \\ \cdots & \cdots & \cdots & \cdots \\ x_{n1} & x_{n2} & \cdots & x_{nd} \end{bmatrix} \quad (1)$$

麻雀种群的适应度值表示如式(2)所示。其中, f 表示个体的适应度值,即麻雀个体的能量储备值。适应度值与能量储备值呈正相关。

$$\mathbf{F}_x = \begin{bmatrix} f([x_{11} & x_{12} & \cdots & x_{1d}]) \\ f([x_{21} & x_{22} & \cdots & x_{2d}]) \\ \cdots & \cdots & \cdots & \cdots \\ f([x_{n1} & x_{n2} & \cdots & x_{nd}]) \end{bmatrix} \quad (2)$$

发现者的位置更新表示如式(3)所示。其中, t 代表当前迭代数, $iter_{\max}$ 表示最大迭代次数。 $\alpha \in (0, 1]$ 是一个随机数。 Q 是服从正态分布的随机数。 \mathbf{L} 表示 $1 \times d$ 的全 1 矩阵。 $R_2 \in [0, 1]$ 和 $ST \in [0.5, 1]$ 分别表示警戒值和安全值。当警戒值大于等于安全值时,发现者将带领其他麻雀撤离危险区域。

$$X_{ij}^{t+1} = \begin{cases} X_{ij} \cdot \exp\left(-\frac{i}{\alpha \cdot iter_{\max}}\right), & R_2 < ST \\ X_{ij} + Q \cdot \mathbf{L}, & R_2 \geq ST \end{cases} \quad (3)$$

跟随者的位置更新表示如式(4)所示。其中, X_p 为全局最优位置, X_{worst} 表示全局最差位置。 \mathbf{A} 表示一个 $1 \times d$ 的矩阵,其中每个元素随机赋值为 1 或 -1,满足 $\mathbf{A}^1 = \mathbf{A}^T (\mathbf{A} \mathbf{A}^T)^{-1}$ 。当 $i > n/2$ 时,这表明适应度值较低的第 i 个跟随者没有获得食物,处于十分饥饿的状态,此时需要飞往其他地方觅食,以获得更多的能量。

$$X_{ij}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{worst} - X_{ij}^t}{\alpha \cdot iter_{\max}}\right), & i > \frac{n}{2} \\ X_p^{t+1} + |X_{ij} - X_p^{t+1}| \cdot \mathbf{A}^+ \cdot \mathbf{L}, & \text{其他} \end{cases} \quad (4)$$

侦察者的位置更新表示如式(5)所示。其中, X_{best} 表示当前的全局最优位置; β 是步长控制参数,服从均值为 0、方差为 1 的正态分布; $K \in [-1, 1]$ 代表麻雀移动的方向; ϵ 是避免分母出现 0 的最小常数; f_i 则是当前麻雀个体的适应度, f_g 和 f_w 分别是当前全局最好和最差的适应度值。当 $f_i > f_g$ 表示此时的麻雀正处于种群的边缘,极易受到捕食者的攻击; $f_i = f_g$ 时,这表明处于种群中间的麻雀意识到了危险,需要靠近其他的麻雀以此减少它们被捕食的风险。

$$X_{ij}^{t+1} = \begin{cases} X_{best}^t + \beta \cdot |X_{ij}^t - X_{best}^t|, & f_i > f_g \\ X_{ij}^t + K \cdot \left(\frac{|X_{ij}^t - X_{worst}^t|}{(f_i - f_w) + \epsilon}\right), & f_i = f_g \end{cases} \quad (5)$$

2 基于混沌映射和随机游走的 SSA

2.1 Singer 混沌映射

混沌映射是生成混沌序列的一种方法,常见的混沌映射方式有 Logistic 映射、Tent 映射、Circle 映射,而 Singer 映射作为混沌映射的典型代表,数学形式简单,具有遍历性和随机性,因此本文采用 Singer 映射对麻雀初始种群进行混沌映射。Singer 映射的表示形式如式(6)所示。其中 $\mu \in (0.9, 1.08)$, $x \in [0, 1]$ 。

$$x_{k-1} = \mu(7.86x_k - 23.31x_k^2 + 28.75x_k^3 - 13.302875x_k^4) \quad (6)$$

Singer 映射迭代 200 次的分布图如图 1 所示,从图 1 可以看出 Singer 映射均匀分布在 $[0, 1]$ 之间,利用这个特点可以使搜索空间更加均匀,增加麻雀种群的均匀性和多样性,从而增加全局搜索能力。




图 1 Singer 混沌映射迭代图

2.2 随机游走策略

随机游走策略^[11]这一过程应用于搜索之后,目的是对最优麻雀进行扰动变异,进而增加局部寻优能力。随机游走过程在数学上可以表示为:

$$X(t) = [0, \text{cussum}(2r(t_1) - 1), \dots, \text{cussum}(2r(t_n) - 1)] \quad (7)$$

其中, $X(t)$ 为随机游走的步数集, cussum 为计算累加和, t 为随机游走的步数。 $r(t)$ 为一个随机函数, 用式(8)表示, 其中 rand 为 $[0, 1]$ 的随机数。

$$r(t) = \begin{cases} 1, & \text{rand} > 0.5 \\ 0, & \text{rand} \leq 0.5 \end{cases} \quad (8)$$

2.3 基于混沌映射和随机游走的 SSA

与粒子群优化算法一样, SSA 在迭代后期也会出现种群多样性减少, 陷入局部最优解的缺陷^[12]。针对以上问题, 在麻雀种群初始化阶段, 利用 Singer 混沌算子生成 $[0, 1]$ 的混沌数, 增加麻雀初始种群的多样性, 提高全局搜索能力; 在麻雀位置更新后, 融合随机游走策略, 增加最优麻雀的扰动变异。在开始迭代之初, 随机游走边界较大, 有利于提高全局搜索性; 在迭代多次之后, 游走边界变小, 进而提高了

最优位置的局部搜索性。由于可行域存在边界, 为确保能在可行域范围内随机游走, 根据式(9)对其进行归一化。

$$X'_i = \frac{(X_i - a_i) * (d'_i - c'_i)}{b_i - a_i} + c'_i \quad (9)$$

其中, a_i 为第 i 维变量随机游走的最小值; b_i 为第 i 维变量随机游走的最大值; c'_i 为第 i 维变量在第 t 次迭代的最小值; d'_i 为第 i 维变量在第 t 次迭代的最大值。

改进后的算法具体步骤如下: 1) 随机抽样待分类数据点, 作为麻雀搜索聚类候选点。2) 利用混沌映射初始化种群, 迭代次数, 初始化捕食者和跟随者比例。3) 更新跟随者位置。4) 计算适应度值, 并排序。5) 更新捕食者位置。6) 更新跟随者位置。7) 更新侦察者位置。8) 计算适应度值并更新发现者位置。9) 利用随机游走更新最优麻雀位置。10) 判断是否达到迭代次数。若达到则停止迭代, 若未达到则重复步骤 3)~9) 直至达到迭代次数。

2.4 基准函数测试

为了验证改进之后的算法具有更好的寻优性能, 本文选取了 10 个具有不同特点的基准测试函数进行函数寻优的对比试验, 函数具体信息如表 1 所示。

表 1 基准测试函数

类型	函数	维数	范围	最优值
高维单峰	$f_1 = \sum_{i=1}^n x_i^2$	30	$[-100, 100]$	0
	$f_2 = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	30	$[-10, 10]$	0
	$f_3 = \sum_{i=1}^n (\sum_{j=1}^i x_j)^2$	30	$[-100, 100]$	0
	$f_4 = \max\{ x_i , 1 \leq i \leq n\}$	30	$[-100, 100]$	0
	$f_5 = \sum_{i=1}^n ix^4 + \text{random}[0, 1]$	30	$[-1.28, 1.28]$	0
高维多峰	$f_6 = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10]$	30	$[-5.12, 5.12]$	0
	$f_7 = -20 \exp\left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + e$	30	$[-32, 32]$	0
	$f_8 = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{x_i}}\right) + 1$	30	$[-600, 600]$	0
低维多峰	$f_9 = \sum_{i=1}^{11} \left[a_i - \frac{x_1(b_i^2 + b_i x_2)}{b_i^2 + b_i x_3 + x_4} \right]^2$	4	$[-5, 5]$	0.000 30
	$f_{10} = - \sum_{i=1}^5 [(X - a_i)(X - a_i)^T + c_i]^{-1}$	4	$[0, 10]$	-10.153 2

2.5 测试结果

将 SSA、ISSA、PSO 和 SRWSSA 分别运行 30 次, 种群规模设置为 30, 最大迭代次数 500 次, 个体上下界 $[0, 255]$, 发现者和侦察者个数均设置为种群个数的 20%。最优值、

最差值、平均值和标准差如表 2 所示。从表 2 可以得出, SSA、ISSA 和 SRWSSA 在最优值和最差值搜索上均优于 PSO 算法。对于高维单峰函数 f_1 、 f_2 、 f_3 、 f_4 、 f_5 , SRWSSA 能直接搜索到最优值, 并且对 f_1 、 f_3 的寻优能力

和精度达到了 100%,对 f_2 、 f_4 和 f_5 的寻优能力和精度均高于 SSA 和 ISSA 数十个数量级,鲁棒性更强;对于高维多峰函数 f_6 、 f_7 、 f_8 ,SSA、ISSA 和 SRWSSA 3 种算法具有相同的寻优性能;对于低维多峰函数 f_9 、 f_{10} ,ISSA 和 SRWSSA 相较于 SSA 算法都能直接搜索到最优值,但是

SRWSSA 在寻优性能上更加优于 ISSA 算法,稳定性也有明显地提升。结果表明,基于 Singer 混沌映射的算法优化了初始种群的多样性,扩大了全局搜索空间,并且基于随机游走策略的方法使最优麻雀的得到进一步改善,局部搜索能力进一步增强。

表 2 函数测试结果

函数	算法	最优值	最差值	平均值	标准差
f_1	SSA	0	3.753 1E-39	1.322 9E-40	1.817 6E-39
	ISSA	0	4.753 1E-42	1.753 1E-51	3.573 2E-52
	PSO	3.046 2E-04	4.035 4E-01	4.538 2e-02	8.816 1E-02
	SRWSSA	0	0	0	0
f_2	SSA	4.451 3E-112	2.682 3E-25	9.169 4E-28	4.187 1E-26
	ISSA	3.753 1E-116	1.485 1E-52	5.912 8E-50	3.348 6E-43
	PSO	6.857 6E-03	4.907 0E-01	1.449 8E-01	1.207 4E-01
	SRWSSA	0	6.363 5E-271	1.716 8E-283	0
f_3	SSA	1.587 2E-222	1.700 3E-27	3.661 5E-29	1.691 7E-30
	ISSA	3.069 7E-228	5.842 1E-54	4.596 2E-52	4.242 1E-52
	PSO	1.015 2E+02	2.232 2E+03	7.412 3E+03	4.730 1E+02
	SRWSSA	0	0	0	0
f_4	SSA	0	3.154 2E-22	1.265 1E-23	4.241 3E-23
	ISSA	0	6.481 5E-127	2.146 4E-127	3.157 4E-129
	PSO	1.917 6	8.317 2	5.029 4	1.463 1
	SRWSSA	0	1.054 4E-186	6.165 6E-143	0
f_5	SSA	2.481 1E-04	5.151 6E-03	1.775 0E-03	1.185 4E-03
	ISSA	1.262 5E-05	3.748 1E-03	3.256 5E-03	3.451 1E-03
	PSO	1.748 3E-02	7.326 7E-02	4.439 2E-02	1.597 1E-02
	SRWSSA	6.998 6E-06	5.721 5E-04	4.448 6E-04	4.255 1E-04
f_6	SSA	0	0	0	0
	ISSA	0	0	0	0
	PSO	2.587 2E+01	1.006 6E+02	4.953 9E+01	1.694 4E-01
	SRWSSA	0	0	0	0
f_7	SSA	8.881 8E-16	8.881 8E-16	8.881 8E-16	0
	ISSA	8.881 8E-16	8.881 8E-16	8.881 8E-16	0
	PSO	1.637 3E-02	2.581 8	1.645 6	0
	SRWSSA	8.881 8E-16	8.881 8E-16	8.881 8E-16	0
f_8	SSA	0	0	0	0
	ISSA	0	0	0	0
	PSO	1.505 5E-03	5.129 3E-01	6.211 4E-02	9.503 6E-02
	SRWSSA	0	0	0	0
f_9	SSA	3.058 4E-04	8.284 5E-04	3.454 1E-04	1.820 5E-04
	ISSA	0.000 30	3.945 2E-04	3.164 5E-04	3.256 4E-06
	PSO	3.705 6E-04	2.036 0E-02	1.311 3E-03	3.625 3E-03
	SRWSSA	0.000 30	0.000 32	0.000 30	0
f_{10}	SSA	-10.153 2	-4.154 1E-00	-7.753 1E-00	-2.415 7E-00
	ISSA	-10.153 2	-6.445 4E-00	-7.842 6E-00	0
	PSO	-10.153 2	-2.631 6E-00	-5.394 7E-00	3.303 0E-00
	SRWSSA	-10.153 2	-10.153 2	-10.153 2	0

3 基于 SRWSSA 的 OSTU 分割算法

3.1 OSTU 算法

OSTU 算法是一种自适应阈值分割算法,根据类间距离极大准则确定最佳阈值^[13-14]。假设一幅图像 M 共有 L 个灰度级,灰度级为 i 的像素有 n_i 个,则图像 M 的总像素 N 为:

$$N = \sum_{i=1}^L n_i \quad (10)$$

灰度级为 i 的像素出现的概率 P_i 为:

$$P_i = \frac{n_i}{N} \quad (11)$$

图像 M 的总灰度均值 μ 为:

$$\mu = \sum_{i=1}^L iP_i \quad (12)$$

以灰度值 k 为阈值将图像分割成 A_0 和 A_1 两部分, A_0 像素灰度级 $[1, k]$, A_1 像素灰度级 $[k+1, L-1]$,则 A_0 、 A_1 出现的概率 P_{A_0} 、 P_{A_1} 分别为:

$$P_{A_0} = \sum_{i=0}^k P_i, P_{A_1} = \sum_{i=k+1}^{L-1} P_i \quad (13)$$

A_0 、 A_1 的灰度均值 E_{A_0} 、 E_{A_1} 分别为:

$$E_{A_0} = \sum_{i=0}^k iP_i | P_{A_0}, E_{A_1} = \sum_{i=k+1}^{L-1} iP_i | P_{A_1} \quad (14)$$

图像 M 的灰度均值 E 为:

$$E = \sum_{i=0}^{L-1} iP_i \quad (15)$$

A_0 和 A_1 的类间方差为:

$$\theta^2(k) = P_{A_0}(E - E_{A_0})^2 + P_{A_1}(E - E_{A_1})^2 \quad (16)$$

使得 $\theta^2(k)$ 取得最大值的 k 即为最佳阈值。若这两个区域间还存在不同的目标,那么还需对这两个区域进一步分割,以遍历整个图像的灰度值,计算每个灰度值的类间方差,从中得到最佳阈值。因此 OSTU 算法的计算效率与图像的尺寸和复杂程度密切相关:尺寸越大,图像越复杂,效率越低。

3.2 基于改进麻雀优化算法的 OSTU 分割算法

针对 OSTU 算法效率低、鲁棒性差的缺点,将改进的 SSA 算法应用于图像分割上。具体步骤如下:1)初始化种群。麻雀种群设置为 20,最大迭代次数设置 50。2)利用

混沌映射增加种群的多样性。3)计算适应度值,并排序。4)更新捕食者位置、跟随者位置和侦察者位置。5)计算适应度值并更新发现者位置。6)利用随机游走策略更新最优麻雀位置。7)达到最大迭代次数后,将搜索到的最优麻雀位置作为最佳阈值。8)阈值分割。

本文算法流程如图 2 所示。

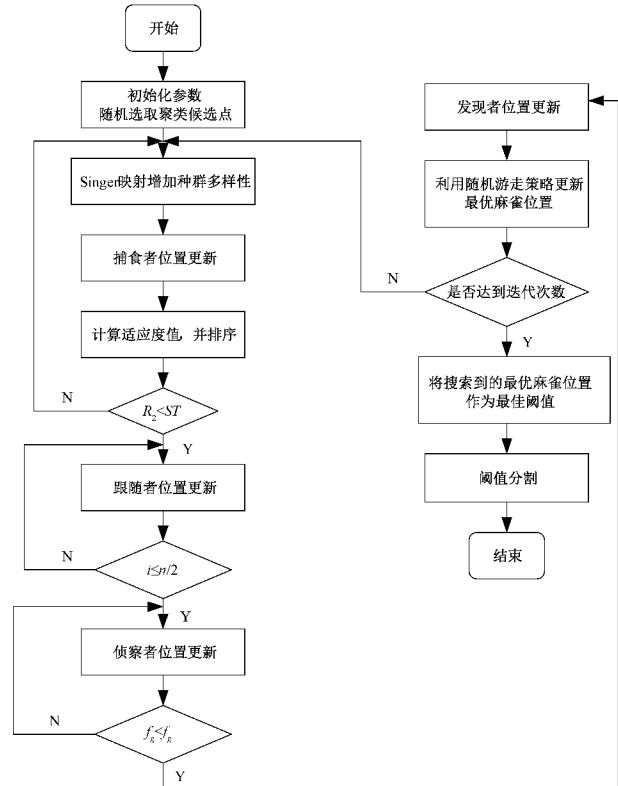


图 2 本文算法流程

3.3 实验结果与分析

为了更直观地对比本文算法在阈值分割上的优势,对 4 幅标准图像分别利用 PSO-OSTU、SSA-OSTU 和 SRWSSA 分割。4 幅图像的分割结果如图 3~6 所示。其中,(a)为原始图像,(b)为 PSO-OSTU 分割结果,(c)为 SSA-OSTU 分割结果,(d)为 SRWSSA 分割结果。从图中可以看出 SSA 和 SRWSSA 的分割效果均优于 PSO 算法,而本文算法细节更清晰,分割质量更优。



图 3 Lena(256×256)

主观判断并不能完全代表结果,因而本文通过计算 PSO-OSTU、SSA-OSTU 和 SRWSSA 的最佳阈值、最少迭

代次数、峰值信噪比^[15](PSNR)和时间效率作为客观评判依据,结果如表 3 所示。从表 3 中数据可以看出,SRWSSA




图 4 Cameraman(256×256)




图 5 Pepper(512×512)




图 6 Truck(512×512)

所得到的最佳阈值优于其他两种算法。Lena 最少迭代次数较 PSO-OSTU 和 SSA-OSTU 分别减少了 65.5%、62.9%；PSNR 值提高了 5.3%、2.0%；时间减少了 27%、7.4%。Cameraman 最少迭代次数较 PSO-OSTU 和 SSA-OSTU 分别减少了 83.3%、76%；PSNR 值提高了 8.2%、11.3%；时间减少了 30.8%、7.6%。Pepper 和 Truck 这两幅图从时间效

率上看，SRWSSA 算法时间上介于 PSO-OSTU 和 SSA-OSTU 之间。Pepper 最少迭代次数较 PSO-OSTU 和 SSA-OSTU 分别减少了 72%、70.2%；PSNR 值提高了 10.5%、8.4%；Truck 最少迭代次数较 PSO-OSTU 和 SSA-OSTU 分别减少了 78%、18%，PSNR 值提高了 6.0%、7.6%。综合来看。本文所提出的 SRWSSA 算法整体分割性能更好。

表 3 3 种算法分割值对比

图像	算法	最佳阈值	迭代次数	PSNR	时间/s
Lena(256×256)	PSO-OSTU	2 232.93	29	5.24	1.722 2
	SSA-OSTU	2 214.98	27	5.41	1.357 2
	SRWSSA	2 235.59	10	5.52	1.255 9
Cameraman(256×256)	PSO-OSTU	3 825.697 6	36	4.51	1.747 4
	SSA-OSTU	3 814.675 8	25	4.67	1.309 5
	SRWSSA	3 826.006 4	6	4.14	1.209 1
Pepper(512×512)	PSO-OSTU	3 319.48	50	3.97	5.356 6
	SSA-OSTU	3 215.59	47	4.02	4.466 9
	SRWSSA	3 221.36	14	4.39	4.746 9
Truck(512×512)	PSO-OSTU	707.06	41	4.48	5.330 2
	SSA-OSTU	697.89	11	4.56	4.612 5
	SRWSSA	709.12	9	4.21	4.945 7

4 结 论

为了优化 SSA 算法的寻优性能和提高收敛速度,本文提出了一种基于 Singer 混沌映射和随机游走策略的 SRWSSA 算法,不仅增强了 SSA 算法的种群多样性和全局搜索能力,并且使算法跳出了局部最优。该算法与 OSTU 算法相结合,在改善图像分割效果的同时,大大缩短了最少迭代次数。引入 PSNR 和时间作为评估标准,与 PSO-OSTU、SSA-OSTU 相比,综合分割性能更好,图像细节更完善,时间上更具优势。在后续研究中将加强麻雀优化算法在其他分割方法上的应用。

参考文献

- [1] SUPRIYANTI R, WIBOWO P F, FIRMANDA F R, et al. Preliminary process in blast cell morphology identification based on image segmentation methods[J]. International Journal of Electrical and Computer Engineering, 2020, 10(6):5714-5725.
- [2] 吴一全,沈毅,刚铁,等. 基于二维对称 Tsallis 交叉熵的小目标图像阈值分割[J]. 仪器仪表学报, 2011, 32(10):2161-2167.
- [3] 王新,白宁波,周君君,等. 基于混合智能算法优化的大地电磁反演法研究[J]. 煤炭科学技术, 2021, 49(7): 147-153.
- [4] 凤丽洲,王友卫,韩琳琳,等. 双重驱动的果蝇优化算法及其在 PID 控制器中的应用[J]. 控制与决策, 2021, 36(9):2225-2233.
- [5] XUE J, SHEN B. A novel swarm intelligence optimization approach: Sparrow search algorithm[J]. Systems ence & Control Engineering An Open Access Journal, 2020, 8(1):22-34.
- [6] LIU G, SHU C, LIANG Z, et al. A modified sparrow search algorithm with application in 3d route planning for UAV[J]. Sensors, 2021, 21(4):1224.
- [7] 李爱莲,全凌翔,崔桂梅,等. 融合正余弦和柯西变异的麻雀搜索算法[J/OL]. 计算机工程与应用, 2021;1-11[2021-09-14]. <http://kns.cnki.net/kcms/detail/11.2127.TP.20210806.0937.008.html>.
- [8] 张伟康,刘升,任春慧. 混合策略改进的麻雀搜索算法[J/OL]. 计算机工程与应用, 2021;1-12[2021-09-14]. <http://kns.cnki.net/kcms/detail/11.2127.TP.20210721.0848.002.html>.
- [9] 段玉先,刘昌云. 基于 Sobol 序列和纵横交叉策略的麻雀搜索算法[J/OL]. 计算机应用, 2021;1-9[2021-09-14]. <http://kns.cnki.net/kcms/detail/51.1307.TP.20210525.1453.002.html>.
- [10] 柳长安,冯雪菱,孙长浩,等. 基于改进麻雀算法的最大二维熵分割方法[J/OL]. 激光技术, 2021;1-15[2021-09-14]. <http://kns.cnki.net/kcms/detail/51.1125.tn.20210423.1018.004.html>.
- [11] 刘策,张花齐,王洪瑞,等. 基于模糊 C 均值聚类和改进的随机游走算法的肺结节分割[J]. 生物医学工程学杂志, 2019, 36(6):978-985.
- [12] 吕鑫,慕晓冬,张钧,等. 混沌麻雀搜索优化算法[J]. 北京航空航天大学学报, 2021, 47(8):1712-1720.
- [13] 吕鑫,慕晓冬,张钧. 基于改进麻雀搜索算法的多阈值图像分割[J]. 系统工程与电子技术, 2021, 43(2): 318-327.
- [14] 江妍,马瑜,梁远哲,等. 基于分数阶麻雀搜索优化 OTSU 肺组织分割算法[J]. 计算机科学, 2021, 48(S1):28-32.
- [15] ABDEL A M, EWEES A A, HASSANIEN A E. Whale optimization algorithm and moth-flame optimization for multilevel thresholding image segmentation[J]. Expert Systems with Applications, 2017, 83:242-256.

作者简介

李鹏,教授,博士,主要研究方向为超声成像、北斗定位、图像处理等。

E-mail:20191219086@nuist.edu.cn

丁倩雯,硕士生,主要研究方向为图像处理。

E-mail:1601696405@qq.com