改进樽海鞘群优化 K-means 算法的图像分割

李志杰¹,王力^{1,2},张习恒¹

(1.贵州大学 大数据与信息工程学院,贵阳 550025; 2.贵州工程应用技术学院 信息工程学院, 贵州 毕节 551700)

摘要:目的 针对樽海鞘群算法寻优精度低、易陷入到局部最优,以及 K-means 算法进行图像分割容易 被初始聚类中心干扰等缺点,提出改进樽海鞘群优化 K-means 算法的图像分割。方法 首先利用 Circle 映射来对樽海鞘种群进行初始化;其次引入莱维飞行到领导者和追随者位置更新公式中,使得樽海鞘种 群的多样性得到提高,克服算法陷入到局部最优。最后,对改进樽海鞘群算法先采用 8 个基准函数进行 性能测试;再将改进樽海鞘群算法优化 K-means 进行图像分割。结果 改进算法在寻优精度、稳定性、 收敛速度以及跳出局部最优的本领得到了提高。同时,改进樽海鞘群算法的寻优精度低、易陷入到局部最 优的缺点,很好地优化了 K-means 算法对图像进行准确分割,在图像分割领域具有一定的参考意义。 关键词:樽海鞘群算法; Circle 映射; Levy 飞行; K-means; 图像分割 中图分类号: TP391 文献标识码:A 文章编号: 1001-3563(2022)09-0207-10 DOI: 10.19554/j.cnki.1001-3563.2022.09.028

Improved Salp Swarm Optimization K-means Algorithm for Image Segmentation

LI Zhi-jie¹, WANG Li^{1,2}, ZHANG Xi-heng¹

(1. College of Big Date & Information Engineering, Guizhou University, Guiyang 550025, China; 2. School of Information Engineering, Guizhou University of Engineering Science, Guizhou Bijie 551700, China)

ABSTRACT: In view of the disadvantages of salp swarm optimization algorithm, such as low optimization accuracy, easy to fall into local optimum, and K-means algorithm for image segmentation easily disturbed by the initial cluster center, an improved salp swarm optimization K-means algorithm was proposed for image segmentation. Firstly, circle mapping was used to initialize the salp population. Secondly, Levy flight was introduced into the leader and follower position updating formula to improve the diversity of salp population and overcome the algorithm falling into local optimum. Finally, eight benchmark functions were used to test the performance of the improved salp population swarm algorithm improves the searching accuracy, stability, convergence speed and the ability to jump out of local optimum. At the same time, the K-means algorithm was optimized by improving salp swarm algorithm to improve image segmentation quality effectively. The improved algorithm improves the disadvantages of the original salp swarm algorithm, such as low optimization accuracy and easy to fall into the local optimum, and can effectively optimize the K-means algorithm for accurate image

收稿日期: 2021-08-15

基金项目:贵州省首批国家级新工科研究与实践资助项目(黔教高函〔2018〕209);贵州省教育厅创新群体重大研究资 助项目(黔财教合〔2016〕118)

作者简介: 李志杰 (1996—), 男, 贵州大学硕士生, 主攻优化计算和图像处理。

通信作者:王力(1971-),男,贵州工程应用技术学院教授,主要研究方向为图像处理、机器学习等。

segmentation, which has a certain reference significance in the field of image segmentation. **KEY WORDS:** salp swarm algorithm; circle mapping; Levy flight; K-means; image segmentation

图像分割^[1]就是把人们感兴趣的目标从图像划 分的区域中提取出来的技术过程。图像分割的方法主 要有阈值、区域、边缘和特定理论等^[2]分割方法。

当今,有许多国内外学者不断地引进新思想、新方法来改进图像分割技术。K-means 算法(K-means Clustering Algorithm)^[3]是 20 世纪 60 年代末被Macqueen J 提出的聚类分析算法,该算法对大数据集的处理具有高效和局部区域寻优强等特性,该算法目前已广泛地用在图像处理领域。K-means 聚类算法存在以下的缺点^[4]: K-means 聚类算法要明确初始聚类中心,且对不一样的初始聚类中心会有不一样的结果;K-means 聚类算法还要明确聚类数量,而聚类数量是很难估计的;K-means 聚类算法还受噪声的干扰,以及容易停留在局部最优值等。

随着各种群智能优化算法的提出,现在常见群智 能算法有粒子群算法(Particle Swarm Optimization, PSO)^[5]、灰狼算法 (Grey Wolf Optimizer, GWO)^[6]、 蚁狮算法 (Ant Lion Optimizer, ALO))^[7]、鲸鱼算法 (Whale Optimization Algorithm, WOA)^[8]等。由于 群智能算法具有寻优精度高、收敛迅速、全局搜索能 力较强等特点,为了克服 K-means 聚类算法的缺点, 有许多学者把群智能优化算法与 K-means 聚类算法 进行结合改进,并用于图像分割。曹帅帅等^[9]提出结 合 PSO 与 K-means 算法的图像分割方法,此算法先 对目标图像进行降噪,然后再转换到 HSV 空间;其 次调节 PSO 算法的惯性权重和学习因子;最后根据 粒子的平均适应度小于给定阈值,再转换到 K-means 算法进行局部寻优,直到聚类中心不断更新直至收 敛,并对图像进行分割。该算法使得图像分割的质量 得到一定的提高。杨雨航^[10]提出动态 PSO 优化 K-means 算法来优化图像分割的质量,该算法先使用 双边滤波对图像进行去噪;其次再调节动态惯性权重 来提升 PSO 算法的全局寻优本领;最后把该算法寻 优结果来初始化 K-means 算法的聚类中心, 然后进 行多次迭代直到收敛。该算法使得图像分割的质量有 所提升。李海洋等^[11]提出改进人工蜂群优化 K-means 算法的图像分割方法,首先在蜜源更新公式中,使用 最优适应度关联的自适应邻域搜索策略;其次在蜜源 开采的过程中,使用最优适应度关联的线性递减邻域 寻优方案;最后将改进人工蜂群算法结合 K-means 算法用于进行图像分割。该算法使得图像分割的效 率、质量和稳定性都得到提升,并且可用在要求较高 的图像处理领域。

虽然前面所述的策略进行图像分割时,在效率和 质量上都有所提高,但是以上方案进行图像分割的不 足之处是当算法平均适应度小于某个阈值时,就切换 到 K-means 算法。阈值的选取很重要,选取不当就 会影响分割结果。为了克服以上方案优化 K-means 算法所存在的缺陷,文中方法是将算法进行迭代寻优 结束后,再进入 K-means 算法中进行图像分割,其 中在算法切换时,没有算法平均适应度小于某个阈值 的条件,因此,文中提出改进樽海鞘群优化 K-means 算法的图像分割,使用混沌 Circle 映射和 Levy 飞行 对樽海鞘群算法进行改进,称为融合 Circle 映射和 Levy 飞行的樽海鞘群算法(Circle Levy Salp Swarm Algorithm, CLSSA),随后将 CLSSA 迭代寻优的输 出结果作为 K-means 算法的初始聚类中心,改善 K-means 算法进行图像分割的质量和稳定性。

1 K-means 算法原理

K-means 算法用来进行图像分割时,首先将目标 图像抽象成具有 d 维向量的数据样本点集,可表示为 $M = (M_1, M_2, ..., M_d)$,然后初始聚类中心是从数据样 本点集中选取 K 个,即 $C = (C_1, C_2, ..., C_K)$;其次将 M_i (i = 1, 2, ..., d)按欧氏最小距离分配到 K簇,目标函 数见式(1)。

$$D = \sum_{i=1}^{K} \sum_{M \in C_i} \left\| M_j - C_i \right\|^2$$
(1)

D 越小,说明簇内数据相似度就越高,聚类的效 果也就越好。K-means 在迭代的过程中,目标函数达 到最小时,聚类中心更新公式见式(2)。

$$C_i = \frac{i}{n} \sum_{j=1}^n M_j \tag{2}$$

式中: n_i为第 i 个簇中数据点的数量。通过不断 迭代,当 K 个簇的中心不在有任何变化、变化不大 或者达到迭代条件时,可得出聚类结果。

2 原始樽海鞘群算法

樽海鞘群算法(Salp Swarm Algorithm, SSA)是 Mirjalili 等^[12]于 2017 年受海洋中微生物(樽海鞘) 的聚集行为组成樽海鞘链启发而来的算法。该算法中 使用一种链状的群体模型来描述樽海鞘群的觅食和 移动行为,在该樽海鞘链模型中的组成部分主要有领 导者和追随者。在樽海鞘链中,在链头是领导者,在 链尾是追随者。在樽海鞘算法中,定义每个樽海鞘个 体的位置表示成一个 d 维向量,则 N 个樽海鞘就连成 了樽海鞘链。此时,樽海鞘链就可以看作是一个种群, 因此这个樽海鞘种群就可以用一个 N×d 的矩阵描述, 描述如下。

$$X = \begin{bmatrix} x_1^1 & x_2^1 & \dots & x_d^1 \\ x_1^2 & x_2^2 & \dots & x_d^2 \\ \dots & \dots & \dots & \dots \\ x_1^N & x_2^N & \dots & x_d^N \end{bmatrix}$$
(3)

第*i*个樽海鞘个体的表示见式(4)。

$$X_i = \begin{bmatrix} x_1^i & x_2^i & \dots & x_d^i \end{bmatrix}$$
(4)

在樽海鞘群算法中,种群在捕食或者向食物源位 置移动时,领导者位置更新方式见式(5)。

$$x_{j}^{1} = \begin{cases} F_{j} + c_{1} \left[(\boldsymbol{u}_{j} - \boldsymbol{l}_{j})c_{2} + \boldsymbol{l}_{j} \right] & c_{3} \ge 0.5 \\ F_{j} - c_{1} \left[(\boldsymbol{u}_{j} - \boldsymbol{l}_{j})c_{2} + \boldsymbol{l}_{j} \right] & c_{3} < 0.5 \end{cases}$$
(5)

式中: x_j^i 为第 1 个樽海鞘群领导者在第 j 维空间 的位置; F_j 为食物源在第 j 维空间的位置; u_j 和 l_j 分 别为第 j 维空间的上和下边界且皆为向量;参数 c_2 和 c_3 都为区间 [0,1] 范围内的随机数,参数 c_2 决定的是 领导者移动的长度,参数 c_3 决定的是领导者移动的方 向。参数 c_1 在 SSA 中是一个很关键的参数,其主要 控制着整个樽海鞘群体的探索本领和开发本领。该参 数受当前樽海鞘种群的迭代次数的影响,其表达式见 式(6)。

$$r_1 = 2e^{-(\frac{4t}{T_{\text{max}}})^2}$$
(6)

式中: t 为当前樽海鞘种群的迭代次数; T_{max} 樽 海鞘种群的最大迭代次数。

追随者的位置更新的公式见式(7)。

$$x_{j}^{i}(t) = \frac{1}{2} \left[x_{j}^{i}(t-1) + x_{j}^{i-1}(t-1) \right]$$
(7)

式中: x^{*i*}_{*j*}(*t*)为经过第*t*次迭代时,第*i*个樽海鞘 追随者在第*j* 维空间的位置。

3 改进 SSA 的策略

3.1 Circle 混沌初始化

大部分群智能优化算法由于在没有先验条件的 情况下,种群个体的初始化都是用随机生成种群个体 位置的方式,原始樽海鞘群算法亦是如此。这种随机 生成种群个体位置的方式容易使得种群位置分布不 均匀,导致搜索空间小。

混沌序列拥有遍历性、非周期性等性点,其基本 思路是根据混沌的特点,首先变量映射在混沌变量的 定义域内,其次再把解转化到个体搜索空间。使用混 沌序列的这些性质,使得种群个体初始化分布更加均 匀,搜索空间广,进而改善算法的性能。匡芳君等^[13] 提出使用 Tent 混沌对种群个体位置进行初始化,使得 种群个体尽量均匀分布在搜索区域内,进而优化蜂群 算法的寻优本领,因此,文中尝试使用 Circle 映射^[14] 对樽海鞘种群进行初始化,其混沌序列定义见式(8)。

$$y_{j+1}^{i} = \text{mod}\left[y_{j}^{i} + 0.2 - (\frac{0.5}{2\pi})\sin(2\pi y_{j}^{i}), 1\right]$$
(8)

式中: *i*=1, 2, 3,..., *N* 为种群数量; *j*=1, 2, 3,..., *d* 为混沌序列变量序号; *y^j* 为种群数量 *i* 中第 *j* 个混沌 序列变量。

将式(8)中得到的 d 个混沌序列 y_i^i 再映射到个体搜索空间,即可得到初始个体的位置 x_i^i ,见式(9)。

$$\boldsymbol{x}_{i}^{i} = \boldsymbol{y}_{i}^{i} \left(\boldsymbol{u}_{i} - \boldsymbol{l}_{i} \right) + \boldsymbol{l}_{i} \tag{9}$$

式中: xⁱ, 为第 i 个个体在第 j 维的位置

与随机种群初始化相比,使用 Circle 混沌映射 对樽海鞘群算法进行初始化,使得种群多样性得到 提升,种群搜索范围变广,进而提升了算法的寻优 性能。

3.2 Levy 飞行策略

在算法的迭代后期容易造成明显的趋同性,即领 导者会涌入到食物源周围的搜索区域;同时,追随者 也会涌入领导者周围的搜索区域,故而造成食物源和 领导者周围区域的樽海鞘种群密度太大,降低了樽海 鞘种群的多样性,致使易于陷入到局部最优,会导致 樽海鞘种群在迭代后期的寻优性能下降。王海瑞等[15] 提出将 Levy 飞行产生的随机步长应用到麻雀加入者 位置更新策略中,其主要利用的是 Levy 飞行随机步 长和方向具有不确定性,用以增加麻雀加入者寻优方 向的多元性,从而增加种群中个体位置的多样性,进 而提升局部寻优本领,避免算法陷入到局部最优。文 中针对以上现象对樽海鞘领导者和追随者的位置更 新提出改进,尝试将 Levy 飞行产生的随机步长应用 到领导者和追随者的位置更新策略中来,这样就可以 克服陷入局部最优,提高樽海鞘种群的多样性,进一 步提升算法的寻有能力。Levy 飞行运动步长^[16]的计 算式见式(10)。

$$\begin{cases} s = \mu / |v|^{1/\beta}, \beta = 1.5 \\ \mu \sim N(0, \sigma_{\mu}^{2}), v \sim N(0, \sigma_{\nu}^{2}) \\ \sigma_{\mu} = \left\{ \frac{\Gamma(1+\beta)\sin(\pi\beta/2)}{\beta \cdot \Gamma[(1+\beta)/2] \cdot 2^{(\beta-1)/2}} \right\}^{1/\beta}, \sigma_{\nu} = 1 \end{cases}$$
(10)

式中: *s*为 Levy 运动步长; $\sigma_{\mu}^{2} \pi \sigma_{\nu}^{2}$ 分别为参数 $\mu \pi \nu$ 的方差, $\mu \pi \nu$ 都服从正态分布。

通过引入 Levy 飞行随机步长,则领导者位置更 新策略见式(11)。

$$\boldsymbol{x}_{j}^{1} = \begin{cases} F_{j} + c_{1} \left[(\boldsymbol{u}_{j} - \boldsymbol{l}_{j}) \cdot \boldsymbol{s} + \boldsymbol{l}_{j} \right] & c_{3} \ge 0.5 \\ F_{j} - c_{1} \left[(\boldsymbol{u}_{j} - \boldsymbol{l}_{j}) \cdot \boldsymbol{s} + \boldsymbol{l}_{j} \right] & c_{3} < 0.5 \end{cases}$$
(11)

式中: x_j^1 为第1个樽海鞘群领导者在第 j 维空间的位置。

追随者位置更新策略见式(12)。

 $x_{j}^{i}(t) = \frac{s}{2} \left[x_{j}^{i}(t-1) + x_{j}^{i-1}(t-1) \right]$ (12)

式中: $x_{j}^{i}(t)$ 为经过第t次迭代时,第i个樽海鞘追随 者在第j维空间的位置。

3.3 CLSSA 算法步骤描述

CLSSA 算法实现步骤如下。

1)对各算法参数进行设置,并且给出种群规模数量 N,迭代最大次数 T_{max}。

2) 对樽海鞘种群进行初始化。使用 3.1 节中的 Circle 混沌映射樽海鞘种群进行初始化。

3)对樽海鞘种群的初始适应度值进行计算。利 用测试函数计算出樽海鞘种群初始个体适应度值。

4)挑选出食物源的位置。把第3步中得到的适 应度值进行大小排序,选出适应度值最小的作为食物 源位置。

5)对位置进行更新。食物源的位置被确定之后, 在种群中选一半的个体根据领导者更新策略进行位 置更新,另一半个体根据追随者更新策略进行位置更 新,利用式(10)—(12)对樽海鞘种群中的领导者 和追随者进行位置更新。

6)计算更新适应度值。计算出樽海鞘种群更新 后的适应度值,然后再进行排序,选最小的适应度值 作为更新后的食物源位置。

7)重复第5步和第6步,直到迭代的最大次数时,算法结束并输出全局最优值。

3.4 CLSSA 优化 K-means 算法的图像 分割

基于 CLSSA 优化 K-means 算法结合的图像分割 有 2 个步骤:利用 CLSSA 搜索全局最优解得到初始 聚类中心;利用 K-means 聚类进行局部寻优,直至 迭代结束。

在进行图像分割时,首先将目标图像看作为数据 样本点集为M的d维空间向量,并从中随机选择m个数据点作初始聚类中心。然后将集合M中余下的 数据点分配到这m类,设 M_i 为集合M中的第i个数 据点, C_j 为第j个聚类中心,并且假设此时 $||M_i - C_j||$ 为最小,那么就将数据点 M_i 分配到第j类,此时该 樽海鞘的适应度计算式见式(13)。

$$f_{i} = \sum_{i=1}^{a} \sum_{j=1}^{m} \left\| M_{i} - C_{j} \right\|$$
(13)

当 CLSSA 达到最大迭代次数后,把寻优得到的 全局最优值来初始化下一个过程 K-means 聚类算法 的聚类中心,从而克服 K-means 聚类算法受聚类中 心初始化的影响等缺点,进一步提高 K-means 算法 的性能。

3.5 CLSSA 优化 K-means 算法的图像分 割步骤描述

算法实现步骤如下。

1)先让 CLSSA 进行寻优,如 3.3 节所示,其中 3.3 节的第 3 步用式(13)作为适应度函数来求解樽 海鞘群的适应度。当到第 7 步迭代结束时,将算法迭 代寻优的最优值输出为 K-means 聚类算法聚类中心 的初始化.

2)根据式(1)计算数据点到聚类中心距离。

3)然后再根据式(2)继续搜索最优解,直到 聚类中心没有发生改变,则输出结果;否则,返回 第2步。

4 实验结果与分析

实验是在 Intel(R)Core(TM) i5-4200H CPU G530@2.80 GHz 以及 Windows 10 操作系统, Matlab R2017b 软件上完成的。为了验证 CLSSA 的性能, 文中分别做了基准函数对比实验和 CLSSA 优化 K-means 的图像分割实验。

4.1 基准函数对比实验

对于基准函数的对比实验,文中实验测试的基准 测试函数共有8个。表1中基准函数分别有单峰函数 和多峰函数,其中 F1-F5 为单峰函数,是用来检测 算法的收敛速度,且单峰函数 F1-F5 在定义域内只 有1个极大或极小值的函数;而F6-F8为多峰函数, 是用来检测算法的探索本领和开发本领,多峰函数 $F_6 - F_8$ 有多个全局最优解或者局部最优解的函数。为 了让实验具有公平性,把所有算法的种群规模都规定 为 30, 种群迭代次数最大值设置为 1 000, 维度设置 为 30, PSO 的参数设置为 vmax=6、wmax=0.9、wmin=0.4、 $c_1=c_2=2$ 。在同一运行环境下进行 30 次, CLSSA、原 始 SSA^[12]、PSO^[5]、ALO^[7]的最优值、平均值和标准 差等实验结果见表 2。CLSSA 与对比算法的收敛曲线 见图 1。张达敏等[17]提出成功率的计算公式为实验成 功的次数除以实验的总次数,判断一次实验能否成功 的表达式见式(14)。

$$\begin{cases} \left| F_{\rm A} - F_{\rm T} \right| / F_{\rm T} < 10^{-3} & F_{\rm T} \neq 0 \\ \left| F_{\rm A} - F_{\rm T} \right| < 10^{-3} & F_{\rm T} = 0 \end{cases}$$
(14)

式中: *F*_A 为算法每次求解的最优值; *F*_T 为基准 测试函数的理论最优值。

实验结果中,算法的寻优精度和寻优本领使用最优值(best)和平均值(mean)来体现,而算法的稳定性以及是否具有跳出局部本领使用标准差(std)和成功率(SR)来体现。

Tab.1 Benchmark testing functions						
函数表达式	维度	搜索区间	理论值			
$F_1 = \sum_{i=1}^n x_i^2$	30	[-100,100]	0			
$F_2 = \sum_{i=1}^{n} x_i + \prod_{i=1}^{n} x_i $	30	[-10,10]	0			
$F_3 = \sum_{i=1}^n (\sum_{j=1}^n x_j^2)$	30	[-100,100]	0			
$F_4 = \max\left\{ x_i , 1 \le i \le n \right\}$	30	[-100,100]	0			
$F_5 = \sum_{i=1}^{n} ix_i^4 + rand(0,1)$	30	[-1.28,1.28]	0			
$F_6 = \sum_{i=1}^{n} [x_i^2 - 10\cos(2\pi x_i) + 10]$	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			
$F_8 = \frac{1}{4\ 000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos(\frac{x_i}{\sqrt{i}}) + 1$	30	[-600,600]	0			

表 1 基准测试函数 Tab.1 Benchmark testing functions

从表 2 中可以看出,对于单峰函数 $F_1 - F_5$, CLSSA 的寻优精度与其他算法相比,其精度最高。 例如在求解 F_3 时,与原始 SSA 相比,CLSSA 最优解 可以达到 1.00×10^{-30} ,平均值为 1.00×10^{-18} ;而 SSA 寻优本领较低,其收敛的最优解为 10.0,平均值为 1.00×10^2 ;两者最优解精度相差 1.00×10^{-31} 个数量级 的误差,平均值相差 1.00×10^{-20} 个数量级误差。与 PSO 和 ALO 相比,CLSSA 仍然具备较好的寻优本领。对 于多峰函数 $F_6 - F_8$,CLSSA 在函数 F_6 和 F_8 中进行求 解时,收敛精度最高能近似达到理论最优值 0;与 SSA、PSO 和 ALO 相比,依旧具有较好的寻优本领。 总体而言,CLSSA 的寻优精度不管对单峰基准函数 或者多峰基准函数进行求解时,其寻优性能显现出比 原始 SSA、PSO 和 ALO 都要好。

此外, 从表 2 可看出, CLSSA 的标准差比原始 SSA、PSO 和 ALO 都要小, 在所有基准测试函数中 的成功率都达到 100%, 这表明算法 CLSSA 的稳定性 以及跳出局部最优的本领要优于原始 SSA、PSO 和 ALO; 而 SSA、PSO 和 ALO 只有在 *F*₁ 才达到 100%, 在其他基准测试函数中的成功率较低或为 0。通过以 上分析可得, CLSSA 的寻优精度、稳定性和跳出局 部最优的本领都比原始 SSA、PSO 和 ALO 强。 为了更加清楚地看出 CLSSA 的收敛趋势, CLSSA 和对比算法的部分基准函数的收敛曲线见图 1,并且对纵坐标取以 10 为底数的指数幂来表示适应 度值。其中图 1a—b 是单峰函数的平均收敛曲线图, 图 1c—d 是多峰函数的平均收敛曲线图。从图 1a—b 可观察到 CLSSA 算法的前期寻优速度较快,且后期 不断跳出局部最优,收敛精度较高。以图 1a 为例, CLSSA 算法的寻优速度最快、收敛精度高,并且伴 随着迭代次数的不断变大,后期也不断地跳出局部最 优值; 而 SSA 收敛较慢、精度较低,容易陷入局部 最优值; ALO 和 PSO 收敛较慢且寻优精度较低。从 图 1c—d 可看到, CLSSA 算法的收敛速度最快且还 能收敛到最佳值; 而 SSA、ALO 和 PSO 收敛还是较 慢且收敛精度较低。由此可知, CLSSA 具有一定的 可行性和优越性。

4.2 CLSSA 优化 K-means 的图像分割实验

为了证明 CLSSA 优化 K-means 算法进行图像分 割的可行性和有效性,选取经典的 Rice.png 图、 Liftingbody.png 图、Lena.tiff 图和 Tire.tif 图进行实验 测试。实验测试使用 K-means、PSO 优化 K-means (简称 PSO-K)、SSA 优化 K-means (简称 SSA-K) 和文中改进的 CLSSA 优化 K-means(简称 CLSSA-K) 进行对比,各算法参数与5.1节实验一样,种群规模 数量为 30,种群最大迭代次数为 50。此外在 4 个算 法的 K-means 算法部分, 令 Rice 图、Liftingbody 图 和 Lena 图的初始聚类中心数量 k=4, Tire 图的初始聚 类中心数量 k=6,并且对每张图像进行实验 20 次。 实验分割结果用均方误差(σ_{MSE})以及峰值信噪比 (P_{PSNR})^[18]这 2 个量来衡量分割后图像质量的好与 差。 σ_{MSE} 越小则说明分割后的图像质量就越好; P_{PSNR} 越大说明分割图像和原始图像越相似。 σ_{MSE} 和 P_{PSNR} 的定义见式(15)—(16)。

$$\sigma_{\text{MSE}} = \frac{1}{M \times N} \left(\sum_{x=1}^{M} \sum_{y=1}^{N} \left(f\left(x, y\right) - \widehat{f}\left(x, y\right) \right)^2 \right)$$
(15)

$$P_{\rm PSNR} = 10 \times \lg \left(\frac{255^2}{\sigma_{\rm MSE}}\right)$$
(16)

式中: f(x,y)和f(x,y)分别为分割前的原始图 像和分割后的图像。

将上述的4种算法对Rice图、Tire图、Liftingbody 图和Lena图进行图像分割的结果见图 2—5。

从图 2—5 可以看出, CLSSA-K 分割的效果更优 秀。对于 Rice 图像,从图 2 中可看到,K-means 和 SSA-K 分割的效果较不清晰和模糊; PSO-K 分割的 效果相较于前两者稍微有所改善,只是底部的纹理分 割效果不清晰;而 CLSSA-K 分割的结果纹理清晰、 效果较好。对于 Tire 图像,从图 3 中可看到,K-means 算法和 PSO-K 分割出来的效果不理想,不能很好地

表 2 不回昇法水麻稍度対比(年度=30) Tab.2 Comparison table of different algorithm solving accuracy (dimension is 30)							
函数	指标	CLSSA	SSA	PSO	ALO		
F_1	best 值	1.50×10 ⁻²⁸	8.29×10^{-9}	1.02×10^{-11}	5.64×10^{-07}		
	mean 值	5.43×10 ⁻¹⁹	1.27×10^{-8}	4.32×10^{-09}	1.05×10^{-05}		
	std 值	1.78×10 ⁻¹⁸	2.69×10^{-9}	9.00×10^{-09}	8.55×10^{-06}		
	SR 值/%	100	100	100	100		
<i>F</i> ₂	best 值	3.63×10 ⁻¹⁵	5.47×10^{-2}	3.37×10^{-06}	9.91×10^{-02}		
	mean 值	1.15×10 ⁻⁹	0.842	2.56×10^{-04}	$2.60 \times 10^{+01}$		
	std 值	5.93×10 ⁻⁹	0.966	4.73×10^{-04}	$3.96 \times 10^{+01}$		
	SR 值/%	100	0	93.33	0		
F_3	best 值	1.98×10 ⁻³⁰	55.7	4.61	3.82×10^{2}		
	mean 值	7.38×10 ⁻¹⁸	2.93×10^{2}	13.4	1.08×10^{3}		
	std 值	2.82×10 ⁻¹⁷	2.56×10^{2}	7.05	4.57×10^{2}		
	SR 值/%	100	0	0	0		
	best 值	2.59×10 ⁻¹⁶	2.28	0.392	4.02		
<i>г</i>	mean 值	2.82×10^{-11}	9.02	0.618	12.4		
F_4	std 值	5.42×10 ⁻¹¹	4.45	0.172	3.50		
	SR 值/%	100	0	0	0		
	best 值	4.72×10 ⁻⁶	2.94×10^{-2}	4.48×10^{-2}	3.34×10^{-2}		
F_5	mean 值	8.89×10 ⁻⁵	9.17×10^{-2}	8.32×10^{-2}	0.101		
	std 值	8.11×10 ⁻⁵	3.80×10^{-2}	2.09×10^{-2}	3.81×10^{-2}		
	SR 值/%	100	0	0	0		
F_6	best 值	0	19.9	20.2	38.8		
	mean 值	0	60.9	46.3	75.3		
	std 值	0	20.8	13.4	17.9		
	SR 值/%	100	0	0	0		
F_7	best 值	4.44×10 ⁻¹⁵	1.34	3.06×10^{-6}	0.931		
	mean 值	1.33×10^{-10}	2.27	1.29×10^{-4}	2.24		
	std 值	3.17×10 ⁻¹⁰	0.56	4.11×10^{-4}	0.95		
	SR 值/%	100	0	96.67	0		
F_8	best 值	0	3.87×10^{-8}	2.33×10^{-12}	2.50×10^{-4}		
	mean 值	0	8.52×10^{-3}	1.03×10^{-2}	1.29×10^{-2}		
	std 值	0	1.25×10^{-2}	9.96×10 ⁻³	1.28×10^{-2}		
	SR 值/%	100	53.33	36.67	23.33		

素 2 不同質注求解結度对比(维度→30)

注:其中加粗表示最优值。



图 1 部分基准测试函数平均收敛曲线

Fig.1 Average convergence curves of some benchmark functions





图 2 Rice 图片分割结果对比 Fig.2 Comparison of Rice image segmentation results



a Tire 原始图像

b K-means

c PSO-K



图 3 Tire 图片分割结果对比

Fig.3 Comparison of Tire image segmentation results



a Liftingbody 原始图像





c PSO-K



图 4 Liftingbody 图片分割结果对比 Fig.4 Comparison of Liftingbody image segmentation results





图 5 Lena 图片分割结果对比 Fig.5 Comparison of Lena image segmentation results

分割出轮胎轮廓的细节;SSA-K 分割的效果比前两 者好,能保持轮胎轮廓完整性,但纹理比较模糊;与 SSA-K 相比,CLSSA-K 分割的效果可以清晰地看到 轮胎中间和边缘的细节,因此,在图 3 中 CLSSA-K 分割的效果较好、清晰度较高。对于 Liftingbody 图 像,从图 4 中可看到,K-means 算法、PSO-K 算法 和 SSA-K 算法分割出来的效果皆不理想,较为模糊; 与前三者相比,CLSSA-K 分割的效果更清晰。对于 Lena 图像,从图 5 中可以看出,K-means 算法、PSO-K 算法和 SSA-K 算法分割出来的效果都不理想,纹理 细节模糊;而 CLSSA-K 分割的效果更优秀,纹理清 晰,比如眉毛比前三者更清晰。通过以上分析, CLSSA-K 分割性能都优于 K-means 算法、PSO-K 算法和 SSA-K 算法。

不同算法进行图像分割的数据指标对比见表 3。 从表 3 可知, K-means 算法对 4 幅经典图像进行分割 时, σ_{MSE} 都是最大的, P_{PSNR} 都是最小的; 对于 Rice 图、Liftingbody 图和 Lena 图, SSA-K 和 PSO-K 分 割得到的 σ_{MSE} 和 P_{PSNR} 相较于 K-means 算法有很大 改善,并且 PSO-K 优于 SSA-K; 而对于 Tire 图, SSA-K 分割得到的 σ_{MSE} 和 P_{PSNR} 都优于 PSO-K 和 K-means; 与 K-means 算法、PSO-K 和 SSA-K 相比, CLSSA-K 对 Rice 图和 Tire 图分割得到的 σ_{MSE} 都是 最小的, P_{PSNR} 都是最大的。由此可知, CLSSA-K 分 割的效果优秀,具有一定的可行性和优越性。

lab.3 Comparison of the segmentation index of algorithms						
图像	算法	均方误差	峰值信噪比			
	K-means	37.584 3	32.380 7			
Rice	PSO-K	5.074 0	41.077 3			
	SSA-K	7.417 3	39.428 3			
	CLSSA-K	3.985 8	42.125 7			
Tire	K-means	116.867 8	27.453 9			
	PSO-K	17.220 6	35.770 3			
	SSA-K	8.754 2	38.708 7			
	CLSSA-K	5.675 7	40.590 6			
	K-means	20.969 3	34.915 0			
Liftingbody	PSO-K	6.670 7	39.889 1			
	SSA-K	7.655 1	39.291 3			
	CLSSA-K	4.529 7	41.570 1			
Lena	K-means	16.290 6	36.011 4			
	PSO-K	5.638 0	40.619 6			
	SSA-K	6.365 4	40.092 7			
	CLSSA-K	4.725 9	41.386 0			

表 3 各算法分割指标对比

注:其中加粗表示最优值。

5 结语

为了提升使图像分割的质量,文中提出改进樽海 鞘群优化 K-means 算法的图像分割。针对樽海鞘群 算法有寻优精度低、容易陷入到局部最优和 K-means 算法受初始聚类中心干扰等问题,提出融合 Circle 映 射和 Levy 飞行的樽海鞘群算法,然后将其优化 K-means 算法进行图像分割。通过实验数据总结可 得,与原始樽海鞘算法(SSA)、粒子群算法(PSO) 和蚁狮优化算法(ALO)相比,文中的算法寻优精度 高、收敛迅速、稳定性强,以及具备较好地跳出局部 最优解的本领;与 K-means 算法、原始樽海鞘算法 (SSA)、粒子群算法(PSO)和原始樽海鞘算法(SSA) 相比,文中改进算法优化 K-means 算法进行图像分 割,得到的 σ_{MSE} 最小, P_{PSNR} 最大,进一步说明文中 算法提高了图像分割的质量效果。

参考文献:

- 拉斐尔-冈萨雷斯,理查德-伍兹,史蒂芬-埃丁斯. 数字图像处理(MATLAB版)(第二版)[M]. 阮秋琦, 译. 北京:电子工业出版社,2016:202-243.
 GONZALEZ R C, WOODS R E, EDDINS S L. Digital Image Processing Using MATLAB, the Second Edition[M]. RUAN Qiu-qi, Translated. Beijing: Publishing House of Electronics Industry, 2016: 202-243.
- [2] 孙敏,房明磊.基于混沌布谷鸟算法的多阈值灰度图 像分割[J]. 长春理工大学学报(自然科学版),2020,43(1):112-119.
 SUN Min, FANG Ming-lei. Multi-Level Gray-Scale Image Thresholding Based on Chaotic Cuckoo Search Algorithm[J]. Journal of Changchun University of Science and Technology (Natural Science Edition),2020,43(1):112-119.
- [3] MACQUEEN J B. Some Methods for Classification and Analysis of Multivariate Observations[C]// Proceedings the 5th Berkeley Symposium on Mathematical Statistics and Probability, 1967: 281-297.
- [4] FENG Yun-cong, ZHAO Hai-ying, LI Xiong-fei, et al. A Multi-Scale 3D Otsu Thresholding Algorithm for Medical Image Segmentation[J]. Digital Signal Processing, 2017, 60: 186-199.
- [5] KENNEDY J. Particle Swarm Optimization[J]. Proceedings of 1995 IEEE International Conference on Neural Networks, (Perth, Australia), 2011, 4(8): 1942-1948.
- [6] SEYEDALI, MIRJALILI, SEYED, et al. Grey Wolf Optimizer[J]. Advances in Engineering Software, 2014, 69(3): 46-61.
- [7] MIRJALILI S. The Ant Lion Optimizer[J]. Advances in Engineering Software, 2015, 83: 80-98.
- [8] MIRJALILI S, LEWIS A. The Whale Optimization Algorithm[J]. Advances in Engineering Software, 2016, 95(4): 51-67.

- [9] 曹帅帅,陈雪鑫,苗圃,等. 基于 PSO 与 K-均值聚类 算法优化结合的图像分割方法[J]. 计算机与现代化, 2020(1): 22-27.
 CAO Shuai-shuai, CHEN Xue-xin, MIAO Pu, et al. Image Segmentation Method Based on Optimization of PSO Algorithm and K-Means Clustering Algorithm[J]. Computer and Modernization, 2020(1): 22-27.
- [10] 杨雨航. 动态粒子群优化 K-means 的图像分割算法研究[J]. 现代计算机(专业版), 2019(8): 63-67.
 YANG Yu-hang. Image Segmentation Algorithm Based on Improved Particle Swarm Optimization and K-Means Clustering[J]. Modern Computer, 2019(8): 63-67.
- [11] 李海洋,何红洲.改进人工蜂群优化的 K 均值图像分 割算法[J].智能计算机与应用,2018,8(3):45-49.
 LI Hai-yang, HE Hong-zhou. Improved Artificial Bee Colony and K-Means Clustering for Image Segmentation[J]. Intelligent Computer and Applications, 2018, 8(3):45-49.
- [12] MIRJALILI S, GANDOMI A H, MIRJALILI S Z, et al. Salp Swarm Algorithm: A Bio-Inspired Optimizer for Engineering Design Problems[J]. Advances in Engineering Software, 2017, 114: 163-191.
- [13] 匡芳君, 徐蔚鸿, 金忠. 自适应 Tent 混沌搜索的人工蜂 群算法[J]. 控制理论与应用, 2014, 31(11): 1502-1509.
 KUANG Fang-jun, XU Wei-hong, JIN Zhong. Artificial Bee Colony Algorithm Based on Self-Adaptive Tent Chaos Search[J]. Control Theory & Applications, 2014, 31(11): 1502-1509.
- [14] 张达敏, 徐航, 王依柔, 等. 嵌入 Circle 映射和逐维小 孔成像反向学习的鲸鱼优化算法[J]. 控制与决策, 2021, 36(5): 1173-1180.
 ZHANG Da-min, XU Hang, WANG Yi-rou, et al. Whale Optimization Algorithm for Embedded Circle Mapping and Onedimensional Oppositional Learning Based Small Hole Imaging[J]. Control and Decision, 2021, 36(5): 1173-1180.
- [15] 王海瑞, 鲜于建川. 改进麻雀搜索算法在分布式电源 配置中的应用[J]. 计算机工程与应用, 2021, 57(20): 245-252.
 WANG Hai-rui, XIANYU Jian-chuan. Application of Distributed Generation Configuration Based on Improved Sparrow Search Algorithm[J]. Computer Engineering and Applications, 2021, 57(20): 245-252.
- [16] 王娟. 基于改进群搜索算法的综合能源系统容量配置 及运行优化[D]. 上海: 上海电机学院, 2020: 32-34.
 WANG Juan. Capacity Configuration and Operation Optimization of Integrated Energy System Based on Improved Group Search Algorithm[D]. Shanghai: Shanghai Dianji University, 2020: 32-34.
- [17] 张达敏,陈忠云,辛梓芸,等.基于疯狂自适应的樽 海鞘群算法[J]. 控制与决策, 2020, 35(9): 2112-2120.
 ZHANG Da-min, CHEN Zhong-yun, XIN Zi-yun, et al. Salp Swarm Algorithm Based on Craziness and Adaptive[J]. Control and Decision, 2020, 35(9): 2112-2120.
- [18] ZHOU Yong-quan, YANG Xiao, LING Ying, et al. Meta-Heuristic Moth Swarm Algorithm for Multilevel Thresholding Image Segmentation[J]. Multimedia Tools and Applications, 2018, 77(18): 23699-23727.