

基于混沌电磁场优化算法的多阈值彩色图像分割

马 军 贾鹤鸣*

(东北林业大学机电工程学院 黑龙江 哈尔滨 150040)

摘 要 为了解决彩色图像多阈值分割中计算时间长、分割精度低的问题,在电磁场优化算法(Electromagnetic Field Optimization, EFO)的基础上引入一种混沌策略用于算法初始化中,提出混沌电磁场优化算法(Chaotic Electromagnetic Field Optimization, CEFO)对图像的最佳阈值向量进行搜索。将其与另外 5 种优化算法进行对比,采用 PSNR、MSSIM 和 FSIM 3 个图像质量评价指标和算法运行时间(CPU Time)对 6 种分割算法进行分析比较。结果表明,CEFO 具有收敛速度快、分割精度高的优势,能够胜任多阈值彩色图像分割的工程任务。

关键词 混沌策略 电磁场优化算法 多阈值分割 彩色图像

中图分类号 TP391 文献标志码 A DOI:10.3969/j.issn.1000-386x.2020.03.041

MULTI-THRESHOLD COLOR IMAGE SEGMENTATION BASED ON CHAOTIC ELECTROMAGNETIC FIELD OPTIMIZATION

Ma Jun Jia Heming*

(College of Mechanical and Electrical Engineering, Northeast Forestry University, Harbin 150040, Heilongjiang, China)

Abstract In order to solve the problem of long computation time and low segmentation accuracy in multi-threshold segmentation of color images, this paper introduces a chaotic strategy based on electromagnetic field optimization(EFO) to initialize the algorithm, and proposes chaotic electromagnetic field optimization(CEFO) to search the optimal threshold vector of the image. It was compared with the other five optimization algorithms. PSNR, MSSIM and FSIM were used to evaluate the image quality, and the computational time(CPU Time) of six segmentation algorithms was analyzed and compared. The results show that CEFO has the advantages of fast convergence and high segmentation accuracy, and can be competent for the engineering task of multi-threshold color image segmentation.

Keywords Chaotic strategy Electromagnetic field optimization Multi-threshold segmentation Color image

0 引 言

图像分割是图像处理中的关键技术之一,分割程度的优劣直接影响到后续的研究进展。数字图像分割技术可以定义为将图像划分为不同区域等级的过程,从而提取出图像中的有效区域^[1]。现如今普遍存在的图像分割方法有阈值法、聚类法、区域法等,其中阈值分割法凭借其高效的性能被广泛应用于各个领域^[2]。基于阈值分割法的关键在于找到精确的阈值数,根据阈值的数量,可将阈值分割法分为单阈值分割和多阈

值分割。目前,使用最广泛、性能最稳定的是最大类间方差法(Otsu)^[3]。相较于技术更为成熟的灰度图像分割,彩色图像分割技术更为复杂,难度更大。但是由于彩色图像比灰度图像更接近人类的视觉特性、包含更丰富的信息,因此对彩色图像分割的研究更具有实际意义。若采用传统遍历搜索方式对彩色图像进行阈值计算,分割效率显然十分低下,不能应用到实际工程中^[4]。因此,需要结合智能优化算法寻找图像的最佳阈值向量。

元启发式智能优化算法用于寻找问题的最优解,在面对复杂困难的问题时,一般能取得较好的效果。

元启发式算法一般是基于自然界的启发,试图通过模仿行为学、生物学、材料学等角度提出的优化算法。例如:鸟群算法(Bird Swarm Algorithm, BSA)^[5]、萤火虫算法(Firefly Algorithm, FA)^[6]、花授粉算法(Flower Pollination Algorithm, FPA)^[7]等都是基于生物学角度提出的智能优化算法;模拟退火算法(Simulated Annealing algorithm, SA)^[8]、风驱动算法(Wind Driven Optimization, WDO)^[9]、引力搜索算法(Gravitational Search Algorithm, GSA)^[10]等都是基于物理学角度提出的智能优化算法。目前,已有不少学者将优化算法应用到图像分割领域中。例如:Sowjanya等^[11]将风驱动算法用于磁共振脑部图像的分割处理,并与粒子群算法等优化算法对比进行定性和定量分析,结果显示该方法在分割处理中的优越性;Rakoth等^[12]将蜻蜓优化算法结合自适应权重(Self-Adaptive DragonFly Optimization, SADFO)用于图像分割实验,结果显示改进后的蜻蜓算法对于图像多阈值分割的效果优于原始的蜻蜓算法。上述研究成果表明将优化算法应用到图像多阈值分割领域中,能够提高算法运行时间。因此,本文采用电磁场优化算法(Electromagnetic Field Optimization, EFO)^[13]并针对图像分割问题对其进行改进,提出一种新的混沌策略用于算法初始化中,名为混沌电磁场优化算法(Chaotic Electromagnetic Field Optimization, CEFO),将CEFO算法应用到彩色图像分割领域中。

1 电磁场优化算法

电磁场优化算法是由文献[3]在2016年提出的一种新型的元启发式智能优化算法,与目前广泛从生物学角度上提出的群智能算法不同,EFO是一种基于物理学中电磁场原理提出的优化算法。在该算法中,电磁粒子(Electromagnetic Particle, EMP)由于受到电磁场中的吸引力和排斥力的作用,不断远离最劣解,朝向最优解运动,最终所有电磁粒子聚集即找到问题的最优解。

1.1 标准电磁场优化算法

通电的铁芯周围产生磁场,形成电磁铁。电磁铁本身只具有一个极性,并且随着电流方向的改变而改变。电磁铁具有吸引和排斥两种特性,同种极性的电磁铁相互排斥,不同极性的电磁铁相互吸引。在EFO算法中,设定吸引力的强度比排斥力高5%~10%,吸引力与排斥力的比例为黄金分割比,促使算法能够在搜索范围内找到最优解。

优化问题的本质就是在限定的空间中找到目标函数的极点及其相对应的极值,这里目标函数称为适应度函数,由目标函数计算得到的值称为适应度值。EFO是一种基于群体的算法,空间中的一个点由一组电磁铁组成的一个电磁粒子表示,若干的电磁粒子构成电磁场中的群体。空间中点的维度对应着电磁粒子中包含的电磁铁数量,因此电磁粒子中的一个电磁铁代表目标函数中的一个变量。算法中规定每个电磁粒子中的电磁铁极性相同,即电磁粒子表现出的极性与其包含电磁铁的极性相同。

EFO算法寻优的机制描述如下:

(1) 在电磁场中随机生成一定数量的电磁粒子,通过适应度函数计算每个电磁粒子的适应度值,根据适应度值对电磁粒子进行排序。

(2) 将电磁场区域分为阳性区、阴性区、中性区。依据适应度值的大小将电磁粒子分为三类:适应度值较好的阳极粒子;适应度值较差的阴极粒子;适应度值居中的中性粒子(规定中性粒子带有几乎为零的阴性)。所有电磁粒子位于相应的电磁场区域。

(3) 在算法的每一次迭代中,都会产生一个新的电磁粒子(EMP^{New}),如果该粒子的适应度值优于原来最差的粒子,则根据其适应度值确定该粒子极性的同时消除原先最差的粒子;否则直接消除 EMP^{New} ,因此电磁粒子逐渐趋于最佳点。

EFO算法的关键在于其每次迭代产生 EMP^{New} 的机制, EMP^{New} 中每个电磁铁都是单独产生的。从三个电磁场区域中分别随机抽取一个电磁粒子,再从抽取出来的三个电磁粒子中分别随机抽取一个电磁铁。此时具有三个不同极性的电磁铁,中性电磁铁受到阳性和阴性电磁铁的吸引和排斥作用,由于吸引力强度高于排斥力且中性电磁铁带有微量阴性,中性电磁铁朝阳性电磁铁方向移动一段距离后达到平衡。换言之, EMP^{New} 中的每个电磁铁均为中性电磁铁受到两性作用后得到的结果,如图1所示。




图1 产生新电磁粒子的示意图

图 1 中阴性电磁铁、中性电磁铁、阳性电磁铁分别用白色、浅灰色、深灰色标记,同时还标注了电磁铁和电磁粒子间的关系。假设 1 个电磁粒子由 3 个电磁铁组成,按照上述产生 EMP^{New} 的机制,则 EMP^{New} 中的 3 个电磁铁是从 9 个原始电磁铁中选取的。这种机制加大了随机性,能够增强算法的寻优力度。

用数学模型将更新 EMP^{New} 的机制描述如下:

$$D_j^{PjKj} = EMP_j^{Pj} - EMP_j^{Kj} \quad (1)$$

$$D_j^{NjKj} = EMP_j^{Nj} - EMP_j^{Kj} \quad (2)$$

$$EMP_j^{New} = EMP_j^{Kj} + [(\varphi \cdot r) \cdot D_j^{PjKj}] - (r \cdot D_j^{NjKj}) \quad (3)$$

式中: j 表示电磁粒子包含电磁铁的数量; EMP_j^{Pj} 表示阳性电磁铁; EMP_j^{Nj} 表示阴性电磁铁; EMP_j^{Kj} 表示中性电磁铁; D_j^{PjKj} 表示阳性电磁铁和中性电磁铁的距离; D_j^{NjKj} 表示阴性电磁铁和中性电磁铁的距离; r 是 $[0,1]$ 的随机数; φ 是黄金分割比 $(\sqrt{5}+1)/2$ 。

为了保持电磁场中粒子的多样性、降低算法陷入局部最优的概率。对于少量的 EMP^{New} , 其中的电磁铁直接设定为随机抽取出的阳性电磁铁;同时,对于部分 EMP^{New} , 只改变其中的一个电磁铁,这样可以提高电磁粒子的混乱程度。电磁粒子间的交叉合作是 EFO 算法的重要特点,这使算法能够快速收敛到全局最优值。并且 EFO 算法中的高混乱程度可以避免算法陷入局部最优。同时, EFO 算法利用黄金分割比的概念合理分配电磁场中吸引力与排斥力的比例,能够更加有效地找到目标函数的最优解。这些特征使 EFO 算法具有强大的寻优能力。

1.2 混沌电磁场优化算法

EFO 算法能高效地解决一般的低维或高维度问题,然而在处理复杂的多维变量问题时表现并不十分理想。为了增强 EFO 算法的寻优精度,同时降低算法的运行时间,本文在标准 EFO 算法的基础上提出了一种新的混沌映射用于电磁粒子的初始化中。

EFO 算法的关键之一在于粒子的混乱程度,混乱程度越大则算法的搜索力度越强。本文对初始电磁粒子的位置进行混沌处理,扰动电磁粒子的分布情况,增大系统初始状态下的不可预测性。混沌现象是指在一个确定系统中由于内在随机性而产生的外在复杂行为,其表现为不确定性、不可重复、不可预测^[14]。在现今众多混沌映射中, Logistic 混沌映射由于其表达简单,随机性能良好被广泛应用,其定义如下:

$$x_{n+1} = \sigma \cdot x_n \cdot (1 - x_n) \quad (4)$$


Logistic 的缺点在于混沌序列分布不均匀,从图 2(a) 中可以观察到,在某些特定值的时候系统出现缺漏,并

没有表现出良好的混沌特性。


本文根据在图像分割中寻找最优阈值向量的问题,提出一种新的混沌映射如下式所示。该混沌映射分布序列如图 2(b) 所示。

$$x_{n+1} = rand() \cdot \sin(2\pi x_n) + x_n \quad (5)$$

由图 2(a)、(b) 对比可以看出,本文提出的混沌映射分布更加广泛和均匀,应用到 EFO 算法的初始化中可以提高电磁粒子的混乱程度,有效避免算法陷入局部最优的情况。



(a) Logistic 混沌映射



(b) 本文混沌映射

图 2 混沌映射序列分布图

2 基于 CEFO 的多阈值分割

阈值分割是图像分割中实用性较强的一类方法,多阈值图像分割即利用 K 个阈值组成的阈值向量 $T = \{t_1, t_2, \dots, t_k\}$ 将图像 I 分成 $K+1$ 个区域 $\{C_0, C_1, \dots, C_k\}$, 本文用最大类间方差法 (Otsu 法) 计算全局最佳阈值向量 T^* 。

假设图像 I 的大小为 $M \times N$, 灰度级为 $L (0 < t_1 < t_2 < \dots < t_k < L)$, 灰度范围为 $\{0, 1, 2, \dots, L-1\}$, 构建图像灰度直方图 $H = \{f_0, f_1, \dots, f_{L-1}\}$, 其中 f_i 是灰度级 i 出现的数。由此,第 i 个灰度级出现的概率为:

$$P_i = \frac{f_i}{L-1} \sum_{i=0}^{L-1} P_i = 1 \quad (6)$$

每一个区域 C_k 的累计概率 w_k 和平均灰度级 μ_k 由下式计算得到:

$$w_k = \sum_{i \in C_k} p_i \quad \mu_k = \sum_{i \in C_k} \frac{i \cdot p_i}{w_k} \quad (7)$$

图像 I 的平均灰度 μ_T 和最大类间方差公式为:

$$\sigma_B^2 = \sum_{k=0}^K w_k \cdot (\mu_k - \mu_T)^2 \quad \mu_T = \sum_{i=0}^{L-1} i \cdot p_i \quad (8)$$

遍历穷举所有灰度级,图像的最佳阈值向量如下式所示:

$$T^* (t_1^*, t_2^*, \dots, t_K^*) = \arg \max_{(t_1, \dots, t_K \in T)} (\sigma_B^2) \quad (9)$$

如果采用穷举法求取最佳阈值向量,随着阈值等级的逐渐升高,算法的计算量将呈指数级增长,运算量惊人。为了提高运算效率,需要结合智能优化算法求解最佳阈值向量。本文利用提出的 CEFO 算法,对多阈值分割中最佳阈值的搜索过程进行寻优,整体流程如图 3 所示。

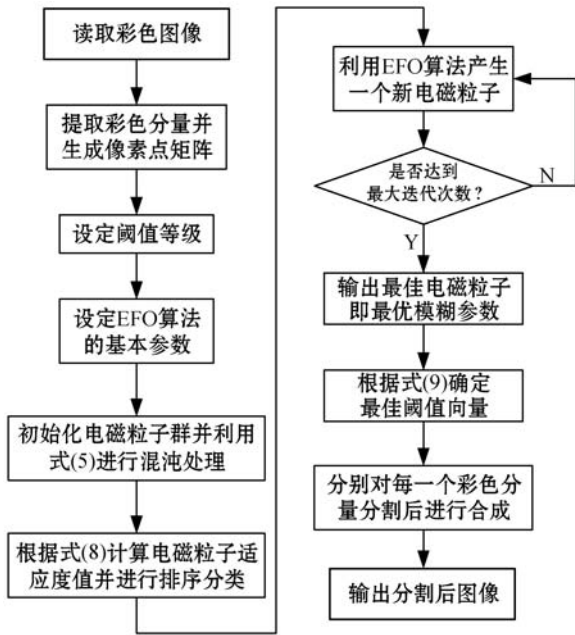


图 3 CEFO 图像分割流程图

3 彩色图像分割实验与分析

为了验证改进后的电磁场优化算法在处理多阈值彩色图像分割问题时的优势性,本文将与 EFO、人工蜂群算法 (Artificial Bee Colony algorithm, ABC)^[15], 蝙蝠算法 (Bat Algorithm, BA)^[16]、WDO 算法、BSA 算法进行对比。其中, EFO 与 WDO 是从物理学角度提出的优化算法; ABC、BA、BSA 是从生物学角度提出的优化算法。每种算法的最大迭代次数设置为 500, 初始种群数量设置为 15, 其他参数如表 1 所示。

表 1 算法参数

算法	参数	取值
EFO	P_{field}	[0.05, 0.1]
	N_{field}	[0.4, 0.5]
	$P_{s_{rate}}$	[0.1, 0.4]
	R_{rate}	[0.1, 0.4]
ABC	$limit$	10
BA	r_i	[0, 1]
	A_i	[1, 2]
WDO	α	[0.8, 0.9]
	g	[0.6, 0.7]
	RT	[1, 2]
	c	[0.05, 3.6]
BSA	a_1, a_2	[0, 2]
	FL	[0.5, 0.9]

本文选用伯克利大学数据库中的图像进行实验, 从中选定了 4 幅分割较为困难的彩色图像在文中进行实验展示并予以分析说明, 如图 4 所示。在 MATLAB 2016b 环境下进行, 应用 6 种优化算法对所选的 4 幅伯克利图像分别取阈值等级 $K=4, 6, 8, 10$ 进行图像分割实验。

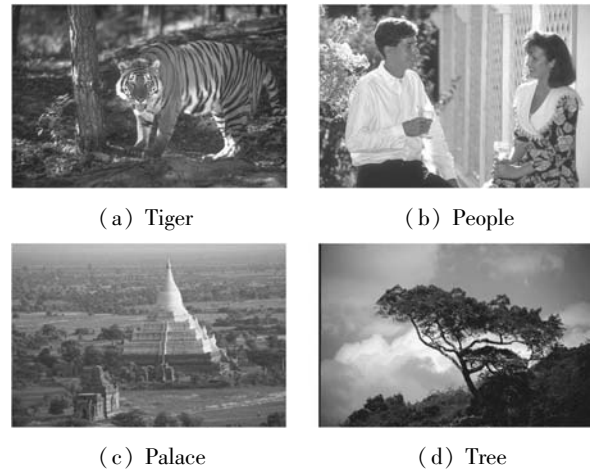


图 4 伯克利大学实验图像

为了更好地评估各算法应用到多阈值彩色图像分割领域的性能, 本文选取 3 个常用的图像质量评价指标和算法运行时间来进行衡量:

(1) 峰值信噪比 (Peak Signal to Noise Ratio, PSNR)^[17]。PSNR 的值越大, 说明图像质量越好。给定大小为 $M \times N$ 的图像 x 和 y , PSNR 定义如下:

$$PSNR(x, y) = 20 \cdot \log_{10} \left(\frac{255}{\sqrt{MSE}} \right)$$

$$MSE = \frac{1}{MN} \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} \|x(i, j) - y(i, j)\|^2 \quad (10)$$

(2) 平均结构相似度 (Mean Structural Similarity, MSSIM)^[18]。MSSIM 的值在 [0, 1] 之间, 越接近 1 表明图像质量越好。MSSIM 是由局部结构相似性求其平均值得到的, 其中 SSIM 的定义如下:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (11)$$

(3) 特征相似度 (Feature similarity, FSIM)^[19]。FSIM 值在 [0, 1] 之间, 越接近 1 表明图像质量越好。FSIM 的定义如下:

$$FSIM(x, y) = \frac{\sum_{x \in \Omega} S_L(X) PC_m(x)}{\sum_{x \in \Omega} PC_m(x)} \quad (12)$$

应用每种算法对 4 幅伯克利实验图像在每个阈值下运行 30 次, 减小随机性造成的干扰, 图像分割评价指标与算法运行时间的平均值如表 2 - 表 5 及图 5 - 图 8 所示。

表 2 伯克利图像指标——CPU Time s

Image	K	CPU Time					
		CEFO	EFO	ABC	BA	WDO	BSA
Tiger	4	0.119 19	0.132 53	3.136 59	1.451 78	1.493 43	1.571 38
	6	0.125 06	0.150 92	3.635 61	1.981 34	2.045 91	2.234 23
	8	0.134 43	0.181 17	4.206 97	2.561 15	2.632 08	2.966 57
	10	0.156 29	0.198 91	5.246 14	3.058 35	3.120 53	3.210 08
	10	0.156 29	0.198 91	5.246 14	3.058 35	3.120 53	3.210 08
People	4	0.105 69	0.124 50	3.276 62	1.534 82	1.729 18	1.683 04
	6	0.127 50	0.149 93	3.894 28	2.069 72	2.197 62	2.231 48
	8	0.152 11	0.174 49	4.551 43	2.862 07	3.086 82	3.093 32
	10	0.161 73	0.210 06	5.371 28	3.090 59	3.240 45	3.458 75
	10	0.161 73	0.210 06	5.371 28	3.090 59	3.240 45	3.458 75
Palace	4	0.104 02	0.131 82	3.225 39	1.533 71	1.840 17	2.009 52
	6	0.109 56	0.145 62	3.624 58	2.071 99	2.116 04	2.215 91
	8	0.129 37	0.156 59	4.414 97	2.660 56	2.698 33	3.051 34
	10	0.142 26	0.178 87	5.573 24	3.169 10	3.261 51	3.543 59
	10	0.142 26	0.178 87	5.573 24	3.169 10	3.261 51	3.543 59
Tree	4	0.104 66	0.139 61	3.452 61	1.580 91	1.725 08	2.107 18
	6	0.112 61	0.162 28	3.965 01	2.034 82	2.124 72	2.457 83
	8	0.122 00	0.176 35	4.748 19	2.590 32	2.648 04	2.956 25
	10	0.156 77	0.196 51	5.691 67	3.152 45	3.297 38	3.563 64
	10	0.156 77	0.196 51	5.691 67	3.152 45	3.297 38	3.563 64

表 3 伯克利图像指标——PSNR

Image	K	PSNR					
		CEFO	EFO	ABC	BA	WDO	BSA
Tiger	4	16.037 8	15.850 4	15.722 0	14.321 2	15.657 6	14.823 0
	6	19.052 9	18.785 1	18.512 6	17.687 2	18.252 1	17.399 4
	8	21.369 2	20.915 3	21.007 9	20.090 2	20.655 3	20.156 8
	10	22.807 1	22.508 5	22.476 2	22.162 3	22.417 4	21.797 6
	10	22.807 1	22.508 5	22.476 2	22.162 3	22.417 4	21.797 6

续表 3

Image	K	PSNR					
		CEFO	EFO	ABC	BA	WDO	BSA
People	4	16.479 7	16.224 2	15.808 9	15.387 0	15.351 6	15.632 9
	6	17.962 0	17.432 9	17.054 7	16.863 6	17.166 8	16.827 1
	8	19.699 3	19.512 7	19.533 4	18.720 6	19.500 1	18.822 0
	10	21.918 1	21.746 2	21.870 4	21.493 6	21.639 9	21.524 5
	10	21.918 1	21.746 2	21.870 4	21.493 6	21.639 9	21.524 5
Palace	4	17.870 4	17.503 9	17.027 7	16.612 8	16.686 3	16.515 2
	6	20.325 1	20.021 3	20.076 2	19.980 6	19.824 8	19.311 9
	8	20.771 9	20.593 2	20.238 4	20.041 5	20.367 5	20.053 8
	10	23.184 3	23.033 5	22.824 4	22.162 9	22.762 7	22.205 7
	10	23.184 3	23.033 5	22.824 4	22.162 9	22.762 7	22.205 7
Tree	4	17.960 7	17.486 0	17.102 5	16.935 8	17.451 7	16.569 0
	6	20.892 5	20.845 0	20.858 7	20.159 2	20.568 5	19.735 4
	8	21.669 1	21.334 6	21.382 7	20.733 0	21.046 6	20.621 0
	10	23.856 7	23.691 6	23.755 9	23.228 9	23.308 5	23.406 9
	10	23.856 7	23.691 6	23.755 9	23.228 9	23.308 5	23.406 9

表 4 伯克利图像指标——MSSIM

Image	K	MSSIM					
		CEFO	EFO	ABC	BA	WDO	BSA
Tiger	4	0.958 66	0.943 12	0.941 92	0.932 01	0.940 17	0.926 42
	6	0.967 35	0.962 80	0.962 44	0.957 69	0.960 51	0.953 05
	8	0.981 35	0.979 85	0.979 34	0.948 29	0.972 99	0.964 42
	10	0.988 15	0.986 51	0.983 29	0.979 59	0.983 78	0.982 15
	10	0.988 15	0.986 51	0.983 29	0.979 59	0.983 78	0.982 15
People	4	0.961 71	0.960 15	0.958 86	0.950 22	0.956 75	0.952 67
	6	0.970 50	0.968 13	0.965 17	0.967 32	0.967 10	0.966 27
	8	0.978 74	0.973 55	0.970 27	0.965 58	0.967 18	0.967 58
	10	0.988 89	0.984 35	0.984 29	0.982 53	0.983 64	0.982 86
	10	0.988 89	0.984 35	0.984 29	0.982 53	0.983 64	0.982 86
Palace	4	0.964 64	0.962 79	0.963 49	0.958 29	0.962 68	0.957 06
	6	0.978 72	0.978 40	0.975 61	0.970 13	0.972 78	0.967 28
	8	0.979 16	0.976 16	0.975 29	0.969 74	0.975 20	0.973 92
	10	0.990 97	0.990 59	0.989 30	0.985 84	0.990 20	0.986 68
	10	0.990 97	0.990 59	0.989 30	0.985 84	0.990 20	0.986 68
Tree	4	0.972 68	0.971 80	0.972 29	0.969 56	0.971 24	0.970 19
	6	0.985 26	0.984 40	0.984 50	0.983 45	0.983 26	0.976 65
	8	0.988 82	0.987 67	0.985 29	0.984 94	0.983 41	0.975 09
	10	0.992 89	0.991 08	0.988 41	0.983 84	0.991 05	0.984 23
	10	0.992 89	0.991 08	0.988 41	0.983 84	0.991 05	0.984 23

表 5 伯克利图像指标——FSIM

Image	K	FSIM					
		CEFO	EFO	ABC	BA	WDO	BSA
Tiger	4	0.756 99	0.748 80	0.742 21	0.729 40	0.724 85	0.691 78
	6	0.798 78	0.779 38	0.741 25	0.736 48	0.766 94	0.721 11
	8	0.834 30	0.826 83	0.829 15	0.818 60	0.824 35	0.810 95
	10	0.857 22	0.842 82	0.839 27	0.833 84	0.834 80	0.829 12
	10	0.857 22	0.842 82	0.839 27	0.833 84	0.834 80	0.829 12
People	4	0.742 41	0.742 03	0.739 13	0.736 39	0.735 09	0.727 77

续表 5

Image	K	FSIM					
		CEFO	EFO	ABC	BA	WDO	BSA
	6	0.813 79	0.807 38	0.799 41	0.781 74	0.790 32	0.750 86
	8	0.833 96	0.830 10	0.818 43	0.802 36	0.825 59	0.798 91
	10	0.854 75	0.844 08	0.838 47	0.825 20	0.823 49	0.825 89
Palace	4	0.722 97	0.720 87	0.721 96	0.698 86	0.722 29	0.626 81
	6	0.793 39	0.789 05	0.790 82	0.789 73	0.785 47	0.738 24
	8	0.811 06	0.805 68	0.806 49	0.785 37	0.796 62	0.767 77
Tree	10	0.850 53	0.842 69	0.831 24	0.822 11	0.840 49	0.802 62
	4	0.765 86	0.761 69	0.753 77	0.744 45	0.754 73	0.734 99
	6	0.829 07	0.821 21	0.818 52	0.806 24	0.814 44	0.809 07
	8	0.833 65	0.830 15	0.830 95	0.821 45	0.832 16	0.827 21
	10	0.881 95	0.881 01	0.879 18	0.862 36	0.875 16	0.865 34

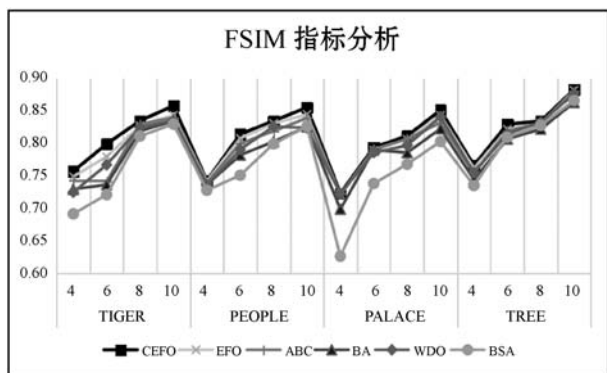


图 8 FSIM 指标分析曲线图

比较各个算法运行时长,CEFO 和 EFO 明显快于其他所有算法,并且 CEFO 运算更快,较 EFO 提高了 15%左右。ABC 的运行时间最长,约为 CEFO 的 30 倍,因此实用性较差。比较 PSNR 指标,CEFO 整体高于其他算法,值得注意的是 ABC 与 WDO 在高阈值时表现抢眼,在某些情况下这两种算法稍优于 EFO 且微劣于 CEFO,说明改进后的电磁场优化算法提高了图像的分割质量和稳定性。比较 MSSIM 指标,CEFO 依然整体高于其他算法,同时可以看出 BA 与 BSA 在从低阈值到高阈值时指标经常发生突变,说明这两种算法应用在图像分割上鲁棒性较差。比较 FSIM 指标,CEFO 整体高于其他算法,该指标目前被认为是非常准确且符合在实际应用中的评价,在该指标中,ABC、BA、WDO、BSA 交替在 4 个阈值中表现较好,说明这几种算法的稳定性较差。通过上述分析,可以看出 CEFO 整体性能优异,较改进前的电磁场优化算法有了一定的提升,具有运行速度快、分割精度高、去噪能力强的特点,能够胜任多阈值彩色图像分割的任务。

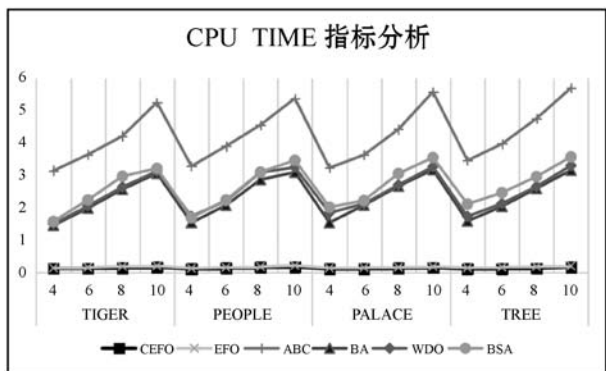


图 5 CPU Time 指标分析曲线图

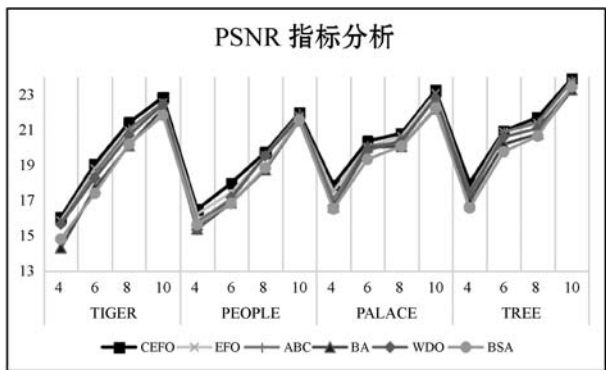


图 6 PSNR 指标分析曲线图




图 7 MSSIM 指标分析曲线图

4 结 语

本文针对彩色图像多阈值分割问题,提出混沌电磁场优化算法用于提高分割效率和精度。将 CEFO 与 EFO、ABC、BA、WDO、BSA 算法进行比较,分别在阈值为 4、6、8 和 10 时对四幅经典伯克利图像进行多阈值分割实验。采用 PSNR、MSSIM、FSIM 指标和算法运行时间对分割后的图像进行质量评估,数据结果显示 CEFO 算法的优势性,具有算法收敛速度快、分割精度高等性能,能够较好地完成彩色图像分割任务,具有较强的工程实用性。下一步将继续研究高阈值分割问题,并针对具体工程问题进行实验分析。

参 考 文 献

[1] Mlakar U, Potocnik B, Brest J. A hybrid differential evolution for optimal multilevel image thresholding[J]. Expert

- Systems with Applications, 2016, 65(1): 221–232.
- [2] 邢致恺, 贾鹤鸣, 宋文龙. 基于莱维飞行樽海鞘群优化算法的多阈值图像分割[J/OL]. 自动化学报: 1–15 [2019-04-11]. <https://doi.org/10.16383/j.aas.c180140>.
- [3] Otsu N. A threshold selection method from gray level histograms[J]. IEEE Transactions on Systems, Man, and Cybernetics, 1979, 9(1): 62–66.
- [4] 潘峰, 孙红霞. 基于蝗虫算法的图像多阈值分割方法[J]. 电子测量与仪器学报, 2019, 33(1): 149–155.
- [5] Wang X H, Deng Y M, Duan H B. Edge-based target detection for unmanned aerial vehicles using competitive Bird Swarm Algorithm[J]. Aerospace Science and Technology, 2018, 78(1): 708–720.
- [6] Rajinikanth V, Couceuro M S. RGB histogram based color image segmentation using firefly algorithm [J]. Procedia Computer Science, 2015, 46(1): 1449–1457.
- [7] Gao M L, Shen J, Jiang J. Visual tracking using improved flower pollination algorithm[J]. Optik, 2018, 156(1): 522–529.
- [8] Mafarja M M, Mirjalili S. Hybrid Whale Optimization Algorithm with simulated annealing for feature selection [J]. Neurocomputing, 2018, 126(1): 302–312.
- [9] Bayraktar Z, Komurcu M, Bossard J A, et al. The wind driven optimization technique and its application in electromagnetics[J]. IEEE Transactions on Antennas and Propagation, 2013, 61(5): 2745–2757.
- [10] Rashedi E, Nezamabadi P H, Saryazdi S. GSA: a gravitational search algorithm [J]. Information Sciences, 2009, 179(1): 2232–2248.
- [11] Kotte S, Pullakura R K, Injeti S K. Optimal multilevel thresholding selection for brain MRI image segmentation based on adaptive wind driven optimization [J]. Measurement, 2018, 130(1): 340–361.
- [12] Sambandam R K, Jayaraman S. Self-adaptive dragonfly based optimal thresholding for multilevel segmentation of digital images[J]. Journal of King Saud University—Computer and Information Sciences, 2018, 30(1): 449–461.
- [13] Abedinpourahotorban H, Shamsuddin S M, Behesht Z. Electromagnetic field optimization: A physics-inspired meta-heuristic optimization algorithm[J]. Swarm and Evolutionary Computation, 2016, 26(1): 8–22.
- [14] Pecora L M, Carroll T L. Synchronization in chaotic systems [J]. Physical review letters, 1990, 64(8): 821.
- [15] Sag T, Cunkas M. Color image segmentation based on multi-objective artificial bee colony optimization[J]. Applied Soft Computing, 2015, 34(1): 389–401.
- [16] Ye Z W, Wang M W, Liu W, et al. Fuzzy entropy based optimal thresholding using bat algorithm[J]. Applied Soft Computing, 2015, 31(1): 381–395.
- [17] Yin P Y. Multilevel minimum cross entropy threshold selection based on particle swarm optimization[J]. Applied Mathematics and Computation, 2007, 184(2): 503–513.
- [18] Wang Z, Bovik A C, Sheikh H R, et al. Image quality assessment: from error visibility to structural similarity [J]. IEEE Transactions on Image Processing, 2004, 13(4): 600–612.
- [19] Sowmya B, Rani B S. Colour image segmentation using fuzzy clustering techniques and competitive neural network [J]. Applied Soft Computing, 2011, 11(3): 3170–3178.
- ~~~~~
- (上接第 201 页)
- [9] Veeriah V, Zhuang N, Qi G J. Differential recurrent neural networks for action recognition [EB]. arXiv:1504.06678, 2015.
- [10] Kim T S, Reiter A. Interpretable 3D human action analysis with temporal convolutional networks [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 2017:1623–1631.
- [11] Kipf T N, Welling M. Semi-supervised classification with graph convolutional networks [EB]. arXiv:1609.02907, 2016.
- [12] Niepert M, Ahmed M, Kutzkov K. Learning convolutional neural networks for graphs [J]. arXiv:1605.05273, 2016.
- [13] Shahroudy A, Liu J, Ng T T, et al. NTU RGB + D: A large scale dataset for 3D human activity analysis [C]//IEEE Computer Vision and Pattern Recognition. 2016:1010–1019.
- [14] Bruna J, Zaremba W, Szlam A, et al. Spectral networks and locally connected networks on graphs [EB]. arXiv:1312.6203, 2013.
- [15] Defferrard M, Bresson X, Vandergheynst P. Convolutional neural networks on graphs with fast localized spectral filtering [EB]. arXiv:1606.09375, 2016.
- [16] Yan S, Xiong Y, Lin D. Spatial temporal graph convolutional networks for skeleton-based action recognition [EB]. arXiv:1801.07455, 2018.
- [17] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016:770–778.
- [18] Szegedy C, Ioffe S, Vanhoucke V, et al. Inception-v4, Inception-ResNet and the impact of residual connections on learning [EB]. arXiv:1602.07261, 2016.
- [19] Liu J, Shahroudy A, Xu D, et al. Spatio-temporal LSTM with trust gates for 3D human action recognition [C]//Computer Vision—ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part III, 2016:816–833.
- [20] Ke Q, Bennamoun M, An S, et al. A New Representation of Skeleton Sequences for 3D Action Recognition [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017:4570–4579.