

基于 Kapur 熵与改进蝴蝶优化算法的电力设备红外图像分割模型

茹传红¹ 樊建惠¹ 赵 洲¹ 申兴发^{2*}

¹(国家电网绍兴供电公司 浙江 绍兴 312000)

²(杭州电子科技大学计算机学院 浙江 杭州 310000)

摘 要 电力设备红外图像分割是电力故障诊断的主要手段。针对传统电力设备图像分割方法计算代价高、分割精度差、速度慢的不足,提出改进蝴蝶优化 Kapur 熵算法对红外图像进行多阈值分割。引入 Levy 飞行策略改进蝴蝶优化算法 IBOA(Improved Butterfly Optimization Algorithm)的位置更新方式,提升算法全局寻优能力;设计高斯混沌变异机制对精英个体进行扰动,提升种群多样性,使算法避免收敛于局部最优。利用基准函数测试 IBOA 的寻优性能。以 Kapur 熵作为 IBOA 的适应度函数,设计基于 IBOA 和 Kapur 熵最大化的图像分割方法,并利用三幅经典伯克利图像和一幅核磁共振图像验证了图像分割性能。将改进算法应用于电力设备红外图像分割,证实算法在非均匀背景和噪声干扰下依然能够有效提高红外图像分割的精度和效率,从而保障电力设备故障诊断成功率。

关键词 Kapur 熵 红外图像分割 电力设备 蝴蝶优化算法 故障诊断 高斯混沌变异

中图分类号 TP393 **文献标志码** A **DOI**:10.3969/j.issn.1000-386x.2025.01.024

INFRARED IMAGE SEGMENTATION MODEL OF ELECTRICAL EQUIPMENT BASED ON KAPUR ENTROPY AND IMPROVED BUTTERFLY OPTIMIZATION ALGORITHM

Ru Chuanhong¹ Fan Jianhui¹ Zhao Zhou¹ Shen Xingfa^{2*}

¹(State Grid Shaoxing Power Supply Company, Shaoxing 312000, Zhejiang, China)

²(School of Computer, Hangzhou Electronic Science and Technology University, Hangzhou 310000, Zhejiang, China)

Abstract Infrared image segmentation of electrical equipment is a main method of electric power fault diagnosis. Aimed at the shortages in traditional electrical equipment image segmentation methods, such as the high computation cost, the poor segmentation accuracy and the low segmentation speed, an improved butterfly optimizing Kapur entropy algorithm is proposed to construct multi-thresholds segmentation. Levy flight strategy was introduced to improve the position update way in improved butterfly optimization algorithm (IBOA), which could promote the global optimizing ability. The Gauss chaos mutation mechanism was applied to disturbance the elite individual and enhance the population diversity, which could avoid the convergence of the algorithm to the local optimum. The optimization performance of IBOA was tested by benchmark functions. Kapur entropy was used as the fitness function of IBOA, and an image segmentation method based on IBOA and Kapur entropy maximization was designed. The image segmentation performance was verified by using three classic Berkeley images and one magnetic resonance image. The improved algorithm was applied on the infrared image segmentation of electrical equipment. It is proved that under the condition of the non-uniform backgrounds and noise interference, the improved algorithm can also effectively promote the segmentation accuracy and efficiency of infrared image so as to ensure the success rate of fault diagnosis of power equipment.

Keywords Kapur entropy Infrared image segmentation Electrical equipment Butterfly optimization algorithm Fault diagnosis Gauss chaos mutation

收稿日期:2021-06-29。国家自然科学基金项目(61672198,61473109);国家自然科学基金重大项目(61190113);科技部 973 前期研究专项(2010CB334707);浙江省自然科学基金项目(LY14F020047)。茹传红,高工,主研领域:电力系统自动化及电力系统图像处理。樊建惠,高工。赵洲,工程师。申兴发,教授。

0 引言

红外热成像诊断是目前电网系统中对电力设备故障诊断的主要手段。电力设备红外图像分割的主要目标是将原始图像划分为唯一特征的特定区域,从中提取用户感兴趣的目标区域,是目前图像处理、模式识别的关键环节^[1]。阈值分割法是图像分割的一种常用方法,特点在于简单易实现,已广泛应用于医学图像、灾害图像、交通图像、电力设备图像处理等领域^[2-4]。由于电力设备受其自身热量和红外辐射的影响,其红外图像往往具有非均匀背景和噪声大的特点,导致出现欠分割或过分割现象。Kapur 熵是阈值分割中常用的分割方法,但传统 Kapur 熵分割法对红外图像进行分割时,采用的是穷举式搜索求解分割阈值的策略,在红外图像具有明显噪声、分辨率不高的情形下,分割效果较差,且其计算时间将随着阈值增加而呈指数增长,计算效率较低,使用局限较大。如何快速准备搜索最优多阈值组合成为电力红外图像分割中的关键问题。

目前,群智能算法因为较强的全局搜索能力和收敛能力已被许多学者应用在多阈值图像分割问题上,一定程度提升了计算效率和分割精度。如:文献[5]利用改进花授粉算法对遥感图像进行了多阈值分割,提升了高维度复杂图像的分割精度。文献[6]提出了基于灰狼优化算法(Grey Wolf Optimization, GWO)的多阈值图像分割方法,利用 Otsu 和 Kapur 熵作为分割阈值模型,结果证实算法比粒子群和细菌觅食算法的性能更优。文献[7]设计了混沌和反向学习机制的改进蜻蜓算法,并应用于多阈值图像分割问题,分割精度和寻优效率都得到一定保证。文献[8]提出新型果蝇优化算法的图像阈值分割算法,以 Kapur 熵作为适应度函数进行寻优,分割阈值稳定且图像分割质量得到一定提升。其他相关群智能算法^[9-12]应用在图像分割最优多阈值求解问题上也表现出较好的分割性能。

蝴蝶优化算法(Butterfly Optimization Algorithm, BOA)^[13]是 2019 年开发的一种模拟蝴蝶群体觅食和求偶行为的新型群智能优化算法。该算法原理简单,依赖参数少,取得了比传统粒子群算法(Particle Swarm Optimization, PSO)、蜂群算法(Bee Algorithm, BA)和灰狼算法 GWO 更好的寻优性能。然而,基本 BOA 依然存在寻优精度低、收敛速度慢等不足,使得算法在寻优稳定性、避免局部最优上仍有进一步的性能提升空间。为此,本文引入 Levy 飞行策略改进 BOA 的位置更新方式,提升算法全局寻优能力;设计基于高斯变异和混

沌 Tent 映射的个体扰动机制,提升种群多样性,使算法具有脱离局部最优的能力,以此实现改进的蝴蝶优化算法(IBOA)。同时,将 Kapur 熵作为 IBOA 的目标函数进行多阈值寻优,设计基于改进蝴蝶优化的 Kapur 熵多阈值图像分割算法。最后对图像分割性能进行实验分析,证实 IBOA 得到的分割阈值更准确,分割精度和分割效率也更高。

1 蝴蝶优化算法 BOA

蝴蝶优化算法 BOA 的思想源于自然界中的蝴蝶觅食行为。蝴蝶可以感知空气气味,以此确定食物源位置或交配对象。同时,蝴蝶个体会散发出一定浓度的香味,通过空气传播,其他蝴蝶可以感知香味,以此实现飞行中种群间的信息互换。香味浓度与寻优适应度相关,当一只蝴蝶嗅到浓度最高(适应度最佳)的香味时,会向目标靠近,该过程为全局搜索。当一只蝴蝶在飞行中无法感知任何香味时,它将作随机移动,该过程为局部开发。

蝴蝶散发的香味浓度大小计算式为:

$$f=c \cdot I^a \tag{1}$$

式中: I 为刺激强度; c 为感知形态; a 为激励指数,理解为不同程度香味的吸收。

随机初始化蝴蝶位置后,种群在各自位置产生香味并扩散,BOA 即进行全局搜索和局部开发阶段。全局搜索中,蝴蝶个体将选择当前全局最优个体的方向移动,表示为:

$$x_i(l+1)=x_i(l)+(r_1^2 \times g^*-x_i(l)) \times f_i \tag{2}$$

式中: $x_i(l)$ 为迭代 l 时蝴蝶个体 i 位置,即代表优化问题的一个候选解; g^* 为当前的全局最优解; r_1 为 $[0,1]$ 间的随机量; f_i 为蝴蝶个体 i 的香味浓度。

局部开发中,蝴蝶无法感知任何香味,它将作随机移动,表示为:

$$x_i(l+1)=x_i(l)+(r_2^2 \times x_j(l)-x_k(l)) \times f_i \tag{3}$$

式中: $x_j(l)$ 、 $x_k(l)$ 为在种群中随机选择的两个蝴蝶个体位置; r_2 为 $[0,1]$ 间的随机量。

全局搜索与局部开发之间通过开关概率 P_{rob} 切换,每次迭代中通过 $[0,1]$ 间的随机值 r_3 与 P_{rob} 比较决定进行全局搜索或局部开发,即 BOA 中个体的位置更新方式为:

$$x_i(l+1)=\begin{cases} x_i(l)+(r_1^2 \times g^*-x_i(l)) \times f_i & r_3 \leq P_{rob} \\ x_i(l)+(r_2^2 \times x_j(l)-x_k(l)) \times f_i & r_3 > P_{rob} \end{cases} \tag{4}$$

2 基于Levy飞行与高斯混沌变异的改进蝴蝶优化算法IBOA

2.1 基于Levy飞行的局部搜索位置更新机制

式(3)表明:蝴蝶个体在进行局部开发时,其移动步长主要由随机参数 r_2 决定。随机变量尽管具有较好的等概率随机性,但搜索行为盲目,效率较低。为此,IBOA引入Levy飞行策略改进BOA中局部开发过程的位置更新方式。

Levy飞行具备高频率短步长搜索和低频率长步长搜索特征,可以有效实现未知区域的随机搜索。Levy飞行结合了高频短步长的跳跃式搜索和低频长步长的行走策略,不仅可以有效地进行局部范围内的精细搜索,还可以确定一定比例的远距离区域内的有效勘探。Levy飞行服从Levy分布,定义为:

$$Levy(\lambda) \sim |s|^{-\lambda} \quad 1 < \lambda \leq 3 \quad (5)$$

式中: s 为随机步长, λ 为指数参数。Levy飞行是一种拥有重尾翼的概率分布。计算搜索路径的Levy因子(飞行步长) $Levy(\lambda)$ 时,通常利用Mantegna模拟Levy飞行路径公式,具体为:

$$s = \mu / |v|^{1/\lambda} \quad (6)$$

式中: $0 < \lambda < 2$,通常取值1.5。参数 μ, v 为服从正态分布的随机数,表示为:

$$\mu \sim N(0, \sigma_\mu^2), v \sim N(0, \sigma_v^2) \quad (7)$$

式中: σ_μ, σ_v 分别定义为:

$$\sigma_\mu = \left[\frac{\Gamma(1+\lambda) \times \sin(\pi \times \lambda/2)}{\Gamma[(1+\lambda)/2] \times \lambda \times 2^{(1+\lambda)/2}} \right]^{\frac{1}{\lambda}} \quad (8)$$

$$\sigma_v = 1 \quad (9)$$

式中: Γ 为标准Gamma函数。

得到Levy飞行路径步长 $Levy(\lambda)$ 后,通过 $Levy(\lambda)$ 取代BOA中局部开发时个体位置更新中的随机值 r_2 ,即可得到IBOA作局部开发时的位置更新式:

$$x_i(l+1) = x_i(l) + (Levy(\lambda))^2 \times x_j(l) - x_k(l) \times f_i \quad (10)$$

$r_3 > P_{rob}$

式中: $Levy(\lambda)$ 为飞行步长; f_i 为蝴蝶个体 i 的香味浓度。

2.2 基于高斯Tent混沌变异的最优个体扰动

由式(2)可知,种群进行全局搜索时,个体移动方向主要由种群中的当前最优个体 g^* 引导,新个体将在 g^* 的邻近区域生成。该方式虽然可以充分利用精英个体的导向作用,但在处理多峰优化问题时,当前的精英个体可能是局部最优,进而导致迭代后期搜索因缺失种群多样性而陷入早熟收敛。为此,IBOA进一步引

进高斯(Gauss)Tent混沌变异对精英个体 g^* 进行扰动,提升种群多样性,扩大搜索空间。

精英个体的变异方式为:

$$g^*(l+1) = \begin{cases} l_{b_{min}} + \psi \times (u_{b_{max}} - l_{b_{min}}) & r_4 \leq 0.5 \\ g^*(l) + g^*(l) \times \phi & r_4 > 0.5 \end{cases} \quad (11)$$

式中: r_4 为(0,1)内的随机值; $[l_{b_{min}}, u_{b_{max}}]$ 为种群中蝴蝶个体的搜索范围; ϕ 为Gauss变异算子; ψ 为Tent混沌值。 ψ 定义为:

$$\psi(l+1) = \begin{cases} \frac{\psi(l)}{\delta} & 0 < \psi(l) < \delta \\ \frac{1-\psi(l)}{1-\delta} & \delta \leq \psi(l) \leq 1 \end{cases} \quad (12)$$

式中: δ 为Tent混沌系数。

Gauss变异算子服从以下Gauss分布:

$$f_{Gauss(0, \zeta^2)}(\phi) = \frac{1}{\zeta \sqrt{2\pi}} e^{-\phi^2/2\zeta^2} \quad (13)$$

式中: ζ^2 为对应每个候选解的方差。通过式(13),可以生成均值为0、标准差为1、服从Gauss分布的随机量。同时,式(11)表明,精英个体将依据概率选择进行Gauss变异或混沌Tent变异,从而确保种群多样性。IBOA进行全局搜索时,将以式(11)对精英个体进行变异,然后替代式(2)中的 g^* 进行搜索。

2.3 IBOA实现

IBOA的执行步骤如下:

步骤1 输入种群规模 N_p 、激励指数 a 、感知形态 c 、开关概率 P_{rob} 、最大迭代数 T_{max} ,并初始化种群。

步骤2 计算所有种群个体的香味浓度和适应度,并确定当前全局最优。

步骤3 比较随机值 r_3 与选择概率 P_{rob} 的大小,根据式(10)进行局部开发,更新个体位置;或根据式(11)对精英个体扰动变异,然后根据式(2)进行全局搜索,并更新种群位置。

步骤4 重新计算所有种群个体适应度,并更新全局最优 g^* 。

步骤5 判断是否达到最大迭代数 T_{max} ,若是,则算法结束,并输出全局最优个体;否则,返回步骤3执行。

3 基于IBOA的Kapur熵最大化多阈值图像分割

3.1 Kapur熵图像分割模型

以Kapur熵最大化为目标进行图像分割的多阈值

选取是将原始图像的灰度直方图划分为多个区域,使各区域熵值和最大。若图像灰度级 $G = \{0, 1, 2, \dots, L-1\}$ 。对于 8 位图,图像灰度级范围为 $[0, 255]$, 则 $L = 256$ 。而图像的熵值可定义为:

$$H = - \sum_{i=0}^{L-1} p_i \ln p_i \quad (14)$$

式中: p_i 为灰度 i 在图像中的所占比例。令分割阈值 $t \in G$, 像素点灰度级小于 t 为目标区域 A , 像素点灰度级大于 t 为目标区域 B 。 A 的概率分布为 $p_i/P_t, i=1, 2, \dots, t$, B 的概率分布为 $p_i/(1-P_t), i=t+1, t+2, \dots, L-1$ 。则区域 A, B 概率分布的 Kapur 熵分别为:

$$H_A = - \sum_{i=0}^t \frac{p_i}{P_t} \ln \frac{p_i}{P_t} \quad (15)$$

$$H_B = - \sum_{i=t+1}^{L-1} \frac{p_i}{1-P_t} \ln \frac{p_i}{1-P_t} \quad (16)$$

式中:

$$P_t = \sum_{i=0}^t p_i \quad (17)$$

整幅图像的 Kapur 熵为 $H = H_A + H_B$ 。当图像进行多阈值分割时,选取阈值组合 t_D , 一共可以将图像划分为 $D+1$ 个目标区域, 则 Kapur 最大熵多阈值图像分割的目标函数可定义为:

$$H(t_1, t_2, \dots, t_D) = - \sum_{i=0}^{t_1} \frac{p_i}{P_{t_0}} \ln \frac{p_i}{P_{t_0}} - \sum_{i=t_1+1}^{t_2} \frac{p_i}{P_{t_1}} \ln \frac{p_i}{P_{t_1}} - \dots - \sum_{i=t_{D-1}+1}^{L-1} \frac{p_i}{P_{t_D}} \ln \frac{p_i}{P_{t_D}} \quad (18)$$

使得 Kapur 熵最大化的灰度级组合 $(t_1, t_2, \dots, t_D)$ 即为最优分割阈值, 该模型可形式化为以下优化问题:

$$TH^*(t_1, t_2, \dots, t_D) = \arg \max H(t_1, t_2, \dots, t_D) \quad t \in D \quad (19)$$

3.2 基于 IBOA 的 Kapur 熵多阈值图像分割算法

对原始图像进行 D 维阈值分割, 多阈值组合 $TH = [t_1, t_2, \dots, t_D]$, 且 $0 < t_1 < t_2 < \dots < t_D < L$ 。以 Kapur 熵作为图像分割基准, 在解空间 L 个灰度级上利用 IBOA 进行最大熵多阈值图像分割求解过程是: 在图像灰度空间内, 利用 IBOA 对分割阈值进行寻优, 以式(18)作为评估蝴蝶个体位置质量优劣的适应度函数。通过迭代寻优, 求解 Kapur 熵到达最大化的阈值 TH^* , 并以 TH^* 对图像进行分割, 评估图像分割质量。

图像分割具体步骤如下:

步骤 1 读取待分割原始图像, 计算图像灰度直方图。

步骤 2 对 IBOA 的参数进行初始化, 包括种群规

模 N_p 、开关概率 P_{rob} 、激励指数 a 、感知形态 c 、最大迭代数 T_{max} 、初始分割阈值数量 D 。

步骤 3 蝴蝶种群初始化。个体位置编码为多阈值组合(按序排列的图像灰度级), 每个位置上的元素分量范围为 $[0, 255]$, 取值为整。

步骤 4 根据式(18)计算蝴蝶个体适应度, 确定全局最优个体 g^* 。

步骤 5 若作局部开发, 根据式(10)更新个体位置。

步骤 6 若作全局搜索, 根据式(11)对当前全局最优个体 g^* 作变异, 再根据式(2)更新个体位置。

步骤 7 重新计算所有种群个体适应度, 更新全局最优 g^* 。

步骤 8 判断终止条件, 若达到最大迭代数 T_{max} , 算法终止, 返回最优适应度的蝴蝶个体位置(全局最优), 即使 Kapur 熵最大化的最优多阈值组合; 否则, 转步骤 4。

步骤 9 根据步骤 8 的最优多阈值组合 TH^* 作图像分割, 输出分割图像并做性能评估。

图 1 是基于 IBOA 的图像分割流程。




图 1 分割算法流程

4 实验分析

4.1 IBOA 的寻优测试实验

为了验证 IBOA 的寻优性能, 先通过基准函数测试该算法的通用性能。引用表 1 的四个基准函数进行测试, 其中: $F_1(x)$ 和 $F_2(x)$ 是单峰函数, 特征是在搜索域内仅有单个最优值, 可以测试全局搜索和收敛能力; $F_3(x)$ 和 $F_4(x)$ 是多峰函数, 特征是在搜索域内有多个局部最优值, 可以测试算法是否陷入局部最优。实验平台为 MATLAB R2019a, 实验环境为 Windows 10 操

作系统,PC 端硬件中 CPU 为 2.4 GHz,内存为 4 GB。相关参数中,最大迭代数为 $T_{\max}=400$,种群规模设为 $N_p=30$,感知形态为 $c=0.01$,激励指数 $a=0.1$,切换概率为 $P_{\text{rob}}=0.8$,参数 c 、 a 、 P_{rob} 均是标准 BOA 中的默认最优取值,混沌系数 $\delta=0.7$,为 Tent 混沌映射的

固定取值。将 IBOA 与传统 BOA^[13]、灰狼优化算法 GWO^[6]、改进非线性灰狼优化算法(Non-Linear Grey Wolf Optimization, NLGWO)^[14] 进行对比。GWO 中的收敛因子为 2, NLGWO 中的非线性调整系数为 3,对比算法的种群规模和最大迭代次数同上。

表 1 测试基准函数用例

基准函数	函数名	搜索区间	最优解 $f_{\min}$	收敛精度	特征
$F_1(x)=\sum_{i=1}^n x_i^2$	Sphere	$[-100,100]$	0	1×10^{-8}	单峰 US
$F_2(x)=\sum_{i=1}^n x_i +\prod_{i=1}^n x_i $	Schwefel 2.22	$[-10,10]$	0	1×10^{-8}	单峰 US
$F_3=\sum_{i=1}^n (x_i^2-10\cos(2\pi x_i)+10)$	Rastrigin	$[-5.12,5.12]$	0	1×10^{-8}	多峰 MS
$F_4(x)=\frac{1}{4\,000}\sum_{i=1}^n x_i^2-\prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right)+1$	Griewank	$[-600,600]$	0	1×10^{-8}	多峰 MS


表 2 是在四种基准函数上进行目标函数寻优,四种算法在目标函数值的平均精度、标准差、最优值、最差值、算法寻优时间上的定量分析结果,为在基准函数上独立运行 30 次的均值结果。可以看出,IBOA 的寻优精度最高,比较 BOA 平均可以提升 47.8% 的寻优精度,较 GWO 则提升为 56.3%,较 NLGWO 提升为 25.38%。在标准差体现的寻优稳定性上,IBOA 比较 BOA、GWO 和 NLGWO 则整体提升了 45.2%、54.1% 和 33.6%。在寻优时间上比较三种对比算法平均减少了 6.2%、8.5%、4.6% 的计算时间。同时,无论单峰还是多峰函数,IBOA 均具有很好的适应性和鲁棒性,表现出优良性能。图 2 是算法寻优收敛曲线,可以看出,IBOA 无论在收敛速度还是寻优精度上都是最优的,且从两个多峰函数上看到,IBOA 具有明显的跳离局部最优能力,而另三种算法最终获得了局部最优解,很难再进一步提升寻优精度。

表 2 算法的寻优结果对比


基准函数	统计指标	GWO	NLGWO	BOA	IBOA
$F_1(x)=$ Sphere	平均精度	4.23E-23	6.35E-32	2.84E-35	0.00E+00
	标准差	3.28E-23	1.21E-32	1.29E-35	0.00E+00
	最优值	5.46E-34	4.20E-49	5.58E-56	0.00E+00
	最差值	6.49E-24	4.28E-35	1.10E-49	0.00E+00
	寻优时间/s	1.593 7	1.213 7	1.209 8	0.897 8
$F_2(x)=$ Schwefel 2.22	平均精度	5.09E-46	5.38E-59	4.03E-57	0.00E+00
	标准差	4.12E-46	3.08E-59	2.81E-57	0.00E+00
	最优解	2.95E-54	2.14E-61	5.16E-67	0.00E+00
	最差值	6.12E-46	6.83E-52	2.04E-54	0.00E+00
	寻优时间/s	1.693 8	1.302 7	1.382 7	0.902 1

续表 2

基准函数	统计指标	GWO	NLGWO	BOA	IBOA
$F_3(x)=$ Rastigin	平均精度	3.67E-06	3.95E-07	7.37E-07	0.00E+00
	标准差	3.35E-06	5.47E-07	6.47E-07	0.00E+00
	最优解	3.78E-13	9.17E-18	4.53E-19	0.00E+00
	最差值	3.25E-09	4.36E-12	1.47E-14	0.00E+00
	寻优时间/s	2.074 5	1.938 4	1.792 1	1.126 3
$F_4(x)=$ Griewank	平均精度	5.48E+03	2.04E+03	3.11E+03	0.00E+00
	标准差	4.82E+03	4.28E+03	5.02E+03	0.00E+00
	最优解	3.55E+03	1.35E+03	1.43E+02	0.00E+00
	最差值	2.05E+05	4.01E+05	1.52E+04	0.00E+00
	寻优时间/s	1.947 5	1.748 9	1.603 9	1.098 3



(a) $F_1(x)$



(b) $F_2(x)$




图2 算法寻优收敛曲线

表3是改变IBOA的三个参数 c 、 a 、 P_{rob} 的取值得到的基准函数寻优结果。实验中,分别在参数的默认最优取值的两侧各取一个值,观测参数变化对IBOA寻优精度的影响。同时,当改变三个参数中的一个参数取值时,另外两个参数均取默认最优值进行实验。观察表3的结果,对于 P_{rob} 参数,其取值决定IBOA进行全局搜索或局部开发的概率。可以看到,在最优取值的基础上,降低或增加取值均无法得到基准函数的理论最优值,原因在于: P_{rob} 值继续增加,会导致局部开发不充分;而降低 P_{rob} 值,全局搜索比例则会降低,这均会影响算法的寻优精度。 c 、 a 的取值改变不如 P_{rob} 值的变化明显,甚至在有些取值情况下,IBOA依然可以在基准函数上得到理论最优值,说明蝴蝶香味浓度的计算对个体适应度的变化并没有产生较大的直接影响,该过程依然由个体的全局搜索和局部开发过程所决定。但综合所有结果来看,在默认值的情况下,IBOA得到理论最优值的概率还是更高,增加和减小取值对算法的寻优精度和收敛速度依然存在着不利影响。

表3 三个关键参数取值对IBOA的影响

基准函数	统计指标	P_{rob}			c			a		
		0.7	0.8	0.9	0.005	0.01	0.05	0.05	0.1	0.2
$F_1(x) = \text{Sphere}$	平均精度	2.35E-112	0	5.19E-54	4.01E-102	0	1.13E-89	0	0	4.32E-110
	标准差	2.90E-112	0	4.98E-54	5.22E-102	0	3.29E-89	0	0	4.12E-110
$F_2(x) = \text{Schwefel 2.22}$	平均精度	4.28E-76	0	4.01E-33	3.38E-99	0	5.16E-77	5.26E-48	0	3.08E-58
	标准差	3.96E-76	0	7.28E-33	0	0	4.76E-77	6.23E-48	0	5.27E-58
$F_3(x) = \text{Rastigin}$	平均精度	1.38E-81	0	6.49E-42	0	0	5.56E-84	7.35E-94	0	4.47E-66
	标准差	4.68E-81	0	2.18E-42	0	0	0	4.38E-94	0	0
$F_4(x) = \text{Griewank}$	平均精度	3.59E-59	0	1.02E-39	6.90E-78	0	3.15E-69	5.56E-89	0	2.03E-90
	标准差	6.01E-59	0	3.34E-39	4.25E-78	0	3.38E-69	3.94E-89	0	3.08E-90

4.2 基于IBOA的多阈值图像分割实验

利用伯克利大学图像分割库中的三幅经典图像Lena、Baboon、Camerman和一幅医学成像领域中的MRI脑核磁共振图进行图像分割实验(大规模实验也可扩展至其他伯克利图像上进行)。实验平台为MATLAB R2019a,IBOA的相关参数同上,分割阈值依次选取2、4、6、8进行实验。除了图像分割效果图的展示,为了准确量化评估图像分割效果,引用峰值信噪比(Peak Signal to Noise Ratio, PSNR)和结构相似度(Structural Similarity Index Measure, SSIM)评估算法性能,定义如下:

$$P_{\text{SNR}} = 10\log_{10}(255^2/M_{\text{SE}}) \tag{20}$$

式中: M_{SE} (Mean Square Error)表示大小为 $m \times n$ 的原始图像 R 与分割图像 K 的均方误差。 M_{SE} 定义为:

$$M_{\text{SE}} = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n [R(i,j) - K(i,j)]^2 \tag{21}$$

$$SSIM(x,y) = \frac{(2\rho_x\rho_y + c_1)(2\varepsilon_{xy} + c_2)}{(\rho_x^2 + \rho_y^2 + c_1)(\varepsilon_x^2 + \varepsilon_y^2 + c_2)} \tag{22}$$

式中: ε_x 、 ε_y 为原始图像和分割图像的方差; ρ_x 、 ρ_y 为原始图像和分割图像的平均灰度; ε_{xy} 为原始图像与分割图像间的协方差, c_1 、 c_2 为常量。

表4是IBOA以Kapur熵最大化作为目标函数,阈值数依次取值2、4、6、8时得到的最优分割阈值、峰值信噪比PSNR和结构相似度SSIM的性能表现。指标PSNR可以评估图像的失真(为分割图像最大像素值

与噪声的比值),PSNR 越大,图像失真越小。而 SSIM 可以从图像对比度、结构信息上评估图像分割性能,SSIM 越大,性能越好。可以看到,分割阈值量的增加可以明显提升图像分割性能,PSNR 和 SSIM 指标明显得到提升,说明分割图像失真越来越小,无论结构信息还是对比度都更加准确。图 3 是 IBOA 在阈值数依次取值 2、4、6、8 时对四幅图像的分割效果。对比原始图像,阈值数的增加使得分割图像中的细节更加清晰,人物/动物脸部轮廓更加完整,分割准确度更高。对于 Lena 图像,人物帽子边缘、头发边缘与背景分割越来越清晰。对于 Baboon 图像,动物的毛发、胡须边界更加清晰。而对于 Cameraman 图像,远景建筑轮廓与背景分割也越来越清晰。而对于 MRI 图像,脑内结构边界逐渐清晰,边缘分割精准度也越来越好。

表 4 IBOA 的图像分割结果

原始图像	阈值量	分割阈值	PSNR	SSIM
Lena	2	{95,160}	17.756 4	0.780 8
	4	{39,92,153,198}	19.035 4	0.803 4
	6	{20,58,99,141,189,201}	27.456 3	0.921 6
	8	{18,57,101,138,181,200,223,246}	31.409 5	0.942 7
Baboon	2	{85,177}	19.704 9	0.681 1
	4	{35,99,148,205}	21.235 8	0.697 6
	6	{29,96,151,193,206,228}	27.356 2	0.861 6
	8	{27,81,140,165,183,211,237,242}	32.446 3	0.913 2
Cameraman	2	{78,145}	20.956 4	0.788 6
	4	{59,118,141,165}	22.780 3	0.821 2
	6	{52,81,109,132,162,191}	27.334 6	0.865 5
	8	{42,65,101,122,157,183,214,245}	30.856 3	0.912 3

续表 4

原始图像	阈值量	分割阈值	PSNR	SSIM
MRI	2	{152,187}	14.385 4	0.801 2
	4	{140,159,186,201}	18.094 7	0.842 8
	6	{132,147,157,190,209,225}	21.573 3	0.903 7
	8	{118,138,150,166,178,198,214,237}	25.912 7	0.927 3




图 3 Lena/Baboon/Cameraman/MRI 的原始图像及 IBOA 在 2-4-6-8 维阈值下的图像分割效果

表 5 是利用 IBOA 进行图像分割后,关键参数变化对计算 PSNR 影响的实验分析,该实验是在 6 维阈值分割情况下的计算结果。可以看到,该结果与表 3 的分析是基本一致的。首先,若进一步在 P_{rob} 最优参数基础上增加或降低取值,图像分割的 PSNR 值都有一定程度降低,说明此时 IBOA 所计算的分割阈值精度已经有所降低,才会导致图像分割误差变大。 c 、 a 取值变化的影响与 P_{rob} 也基本是相似的,说明算法的分割性能与这些关键参数的取值并不是简单的线性关系,而是存在极值点的非线性变化关系。在后续的对比如实验中,三个参数的取值也均使用参数配置中说明的默认最优值进行对比分析。

表 5 关键参数变化对 PSNR 影响的实验分析(6 维阈值分割情况下)

原始图像	P_{rob}				c			a	
	0.7	0.8	0.9	0.005	0.01	0.05	0.05	0.1	0.2
Lena	27.382 7	27.456 3	27.309 1	27.284 9	27.456 3	27.316 3	27.338 9	27.456 3	27.402 6
Baboon	27.287 4	27.356 2	27.208 3	27.298 7	27.356 2	27.220 9	27.210 1	27.356 2	27.212 6
Cameraman	27.098 3	27.334 6	27.109 2	27.201 9	27.334 6	27.198 4	27.278 7	27.334 6	27.085 8
MRI	20.737 4	21.573 3	21.057 6	21.378 4	21.573 3	20.983 4	21.409 1	21.573 3	21.347 5

将 IBOA 进一步与传统 BOA、GWO 和 NLGWO 进行图像分割实验比较,参数配置不变,结果如表 6 所


示。可以看到,IBOA 的分割性能是最好的,在分割阈值数较小时,两个指标 PSNR 和 SSIM 的差距并不大,

说明此时各算法之间的分割效果比较接近。但随着阈值数的进一步增加,差距则越来越明显,说明此时四个算法的寻优性能逐步显现差距。IBOA 利用 Levy 飞行机制和高斯混沌变异机制对于算法的全局搜索能力和收敛速度的提升是有效可行的,它使得图像分割的精度更高,分割阈值求解更加精确,综合分割性能更好。图 4 的 Kapur 熵收敛曲线也证实 IBOA 得到的熵值最大,寻优精度更高,收敛速度更快。从图 5 中各算法的


计算时间也可以看出,增加分割阈值数会增加算法的计算时间,由于此时求解目标阈值维度增加了,算法寻优需要花费更多的时间。但在分割阈值数较少时,算法之间的计算时间相差不大,计算时间上的差异基本在 5% ~ 10% 之间。但增加至更多维的分割阈值时,算法之间的差异性逐渐体现出来,此时 IBOA 可以对比算法中表现最优的算法降低平均约 25.4% 的计算时间,证明改进算法的图像分割效率得到了大幅提升。

表 6 对比实验


原始图像	分割 阈值量	GWO		NLGWO		BOA		IBOA	
		PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
Lena	2	15.113 4	0.712 3	16.038 5	0.745 6	16.947 0	0.743 2	17.756 4	0.780 8
	4	17.847 5	0.720 9	17.093 4	0.741 9	18.886 4	0.750 9	19.035 4	0.803 4
	6	24.746 8	0.765 6	25.011 2	0.798 3	25.343 9	0.814 5	27.456 3	0.921 6
	8	27.036 7	0.796 5	28.485 4	0.801 3	29.917 8	0.850 9	31.409 5	0.942 7
Baboon	2	17.089 8	0.632 5	17.569 3	0.643 8	18.256 1	0.671 2	19.704 9	0.681 1
	4	19.535 2	0.673 8	19.945 3	0.689 4	20.756 5	0.693 4	21.235 8	0.697 6
	6	24.464 3	0.755 1	25.309 4	0.801 1	26.201 0	0.801 2	27.356 2	0.861 6
	8	27.834 4	0.802 2	29.043 4	0.859 3	29.371 2	0.848 9	32.446 3	0.913 2
Cameraman	2	18.027 7	0.734 1	19.012 1	0.758 4	19.604 9	0.761 1	20.956 4	0.788 6
	4	20.852 8	0.755 3	20.495 8	0.794 9	21.887 2	0.804 8	22.780 3	0.821 2
	6	24.978 2	0.798 1	25.309 5	0.824 7	26.302 8	0.850 2	27.334 6	0.865 5
	8	27.609 3	0.820 2	28.495 5	0.880 3	29.547 4	0.892 0	30.856 3	0.912 3
MRI	2	8.095 5	0.659 4	10.984 4	0.712 6	12.094 3	0.798 3	14.385 4	0.801 2
	4	12.309 5	0.690 5	14.309 4	0.738 2	16.443 7	0.801 2	18.094 7	0.842 8
	6	16.443 8	0.712 8	17.412 6	0.794 8	19.039 5	0.848 3	21.573 3	0.903 7
	8	20.048 5	0.756 7	22.564 5	0.864 9	23.204 6	0.893 2	25.912 7	0.927 3




(a) Lena 图像



(b) Baboon 图像



(c) Cameraman 图像



(d) MRI 图像

图 4 Kapur 熵值收敛曲线





图 5 算法的计算时间

4.3 电力设备红外图像分割实验

为了验证 IBOA 对电力设备红外图像的分割效果,利用图 6 所示的两幅红外图像进行实验分析。图 6(a)为高压隔离开关红外图像,图 6(b)为电流互感器红外图像。对比算法沿用前文的三种算法:传统 BOA、灰狼优化算法 GWO 和改进非线性灰狼优化算法 NLGWO,即利用这三种算法结合 Kapur 熵寻找红外图像的分割阈值。其他参数配置不变。



(a) 高压隔离开关 (b) 电流互感器
图 6 电力设备红外图像


图 7 是算法对红外图像进行 2 阈值分割的效果。由于两幅红外图像均带有复杂的背景辐射,三种对比算法均存在对背景的过分割现象,尤其对于电流互感器,底端的支柱绝缘子部分已经存在较为严重的信息丢失。本文的 IBOA 在两幅红外图像上具有更加清晰的分割细节,尤其在复杂的背景辐射条件下,依然能够有效抑制背景信息的噪声干扰,有效实现了在非均匀背景影响下分割区域完整性、分割细节的性能优势。




(a) GWO (b) NLGWO



(c) BOA (d) IBOA



(e) GWO (f) NLGWO



(g) BOA (h) IBOA

图 7 不同算法的红外图像分割

引用红外图像分割指标误分率 (Misclassification Error, ME) 进一步客观量化图像的分割质量。ME 定义如下:

$$M_E = 1 - \frac{|B_s \cap B_r| + |F_s \cap F_r|}{|B_s \cap F_s|} \tag{23}$$

式中: B_s 、 F_s 分别表示电力设备红外图像的二值掩码的背景和前景目标像素点集合; B_r 、 F_r 分别表示图像分割图的背景和前景目标像素点集合; $B_s \cap B_r$ 、 $F_s \cap F_r$ 为对应正确分割像素点集合。由定义可知,ME 值越小,红外图像的分割效果越好。

表 7 是算法在误分率 ME 上的对比结果。可以看出,本文的 IBOA 比较传统 BOA、NLGWO 和 GWO 三种算法在 ME 值上有明显改进。在高压隔离开关红外图像的分割上,IBOA 的 ME 值相比 BOA、NLGWO 和 GWO 三种算法分别平均降低了 27.45%、34.51% 和 68.77%,在电流互感器红外图像的分割上,分别平均降低了 46.36%、48.38% 和 68.52%。

表 7 分割误分率 ME 对比

测试红外图像	误分率 ME			
	GWO	NLGWO	BOA	IBOA
高压隔离开关	0.023 7	0.011 3	0.010 2	0.007 4
电流互感器	0.030 5	0.018 6	0.017 9	0.009 6

5 结 语

本文提出了一种改进 BOA 的 Kapur 熵多阈值图像分割方法,并将其应用于电力设备红外图像分割领域。引入 Levy 飞行改进 BOA 的位置更新方式,提升算法全局寻优能力;利用高斯混沌变异机制对精英个体进行扰动,提升种群多样性,使算法避免收敛于局部最优,实现改进蝴蝶优化算法 IBOA。以 Kapur 熵最大

化作为 IBOA 的适应度函数进行多阈值图像分割。分别对 IBOA 在基准函数上的寻优性能和多阈值图像分割效果进行实验对比分析,在峰值信噪比和结构相似度等分割指标上进行对比分析,证实 IBOA 具有更高的图像分割精度和分割效率,有效提升算法的寻优性能。两幅电力设备红外图像的实验结果证实改进算法可以有效分割红外图像,以有效应对电力系统故障诊断问题。

参 考 文 献

- [1] Pare S, Kumar A, Singh G, et al. Image segmentation using multilevel thresholding: A research review[J]. Iranian Journal of Science and Technology, Transactions of Electrical Engineering, 2020, 44(1): 1–29.
 - [2] 李同英,朱洪波. MATLAB 环境中的人脑医学图像融合与识别方法研究[J]. 中国科技论文, 2016, 11(20): 2368–2374.
 - [3] 胡加鑫,贾鹤鸣,邢致恺,等. 基于鲸鱼算法的森林火灾图像多阈值分割[J]. 森林工程, 2018, 34(4): 70–74.
 - [4] Li Q, He C. A new algorithm of vehicle license plate location based on convolutional neural network[J]. Journal of Computational Methods in Sciences and Engineering, 2018, 18(8): 1–13.
 - [5] Shen L, Fan C Y, Huang X T. Multi-level image thresholding using modified flower pollination algorithm[J]. IEEE Access, 2018, 23(3): 508–519.
 - [6] Khairuzzaman A, Chaudhury S. Multilevel thresholding using grey wolf optimizer for image segmentation[J]. Expert Systems with Applications, 2017, 86(11): 64–76.
 - [7] 鲍小丽,贾鹤鸣,郎春博. 基于改进蜻蜓算法的多阈值彩色图像分割[J]. 计算机应用与软件, 2020, 37(6): 234–241.
 - [8] 信成涛,邹海,盛超,等. 新型果蝇优化算法的最佳阈值图像分割[J]. 微电子学与计算机, 2019, 36(4): 52–56.
 - [9] Aziz M, Ewees A, Hassanien E. Whale optimization algorithm and moth-flame optimization for multilevel thresholding image segmentation[J]. Expert Systems with Applications, 2017, 83(4): 242–256.
 - [10] Elaziz M, Lu S F. Many-objectives multilevel thresholding image segmentation using knee evolutionary algorithm[J]. Expert Systems with Applications, 2019, 125(6): 305–316.
 - [11] Gao Y, Li X, Dong M, et al. An enhanced artificial bee colony optimizer and its application to multi-level threshold image segmentation[J]. Journal of Central South University, 2018, 25(1): 107–120.
 - [12] Zhang S P, Jiang W, Satoh S. Multilevel thresholding color image segmentation using a modified artificial bee colony algorithm[J]. IEICE Transactions on Information and Systems, 2018, 101(8): 2064–2071.
 - [13] Arora S, Singh S. Butterfly optimization algorithm[J]. Soft Computing, 2019, 23(3): 715–734.
 - [14] 谈发明,赵俊杰,王琪. 一种改进非线性收敛方式的灰狼优化算法研究[J]. 微电子学与计算机, 2019, 36(5): 89–95.
-
- (上接第 123 页)
- [9] Zhou X Y, Wang D Q, Krahenbuhl P. Objects as points[EB]. arXiv:1904.07850, 2019.
 - [10] Zhang R. Making convolutional networks shift-invariant again[EB]. arXiv:1904.11486v1, 2019.
 - [11] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[J]. arXiv:1512.03385, 2015.
 - [12] Dumoulin V, Visin F. A guide to convolution arithmetic for deep learning[EB]. arXiv:1603.07285, 2016.
 - [13] Dai J F, Qi H Z, Xiong Y W, et al. Deformable convolutional networks[EB]. arXiv:1703.06211v3, 2017.
 - [14] Zou X Y, Xiao F Y, Yu Z D, et al. Delving deeper into anti-aliasing in convnets[EB]. arXiv:2008.09604, 2020.
 - [15] Wu Y, He K M. Group normalization[EB]. arXiv:1803.08494, 2018.
 - [16] Redmon J, Farhadi A. YOLOv3: An incremental improvement[EB]. arXiv:1804.02767, 2018.
 - [17] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[EB]. arXiv:1506.01497, 2015.
 - [18] Liang C, Papandreou G, Kokkinos I, et al. Semantic image segmentation with deep convolutional nets and fully connected CRFs[EB]. arXiv:1412.7062, 2014.
 - [19] Fisher Y, Vladlen K. Multi-scale context aggregation by dilated convolutions[EB]. arXiv:1511.07122, 2015.
 - [20] Fu C Y, Liu W, Ranga A, et al. DSSD: Deconvolutional single shot detector[EB]. arXiv:1701.06659, 2017.
 - [21] Dai J F, Li Y, He K M, et al. R-FCN: Object detection via region-based fully convolutional networks[C]//30th International Conference on Neural Information Processing Systems, 2016: 379–387.
 - [22] Liu W, Anguelov D, Erhan D, et al. SSD: Single shot multibox detector[C]//European Conference on Computer Vision, 2016: 21–27.
 - [23] Jia D, Wei D, Socher R, et al. ImageNet: A large-scale hierarchical image database[J]. IEEE Computer Vision & Pattern Recognition, 2009: 248–255.
 - [24] Everingham M, Winn J. The PASCAL visual object classes challenge 2007 (VOC2007) development kit[J]. International Journal of Computer Vision, 2006, 111(1): 98–136.
 - [25] Everingham M, Eslami S, Gool L V, et al. The pascal visual object classes challenge: A retrospective[J]. International journal of computer vision, 2015, 111(1): 98–136.