

文章编号 1004-924X(2015)10-2943-09

动态迁移和椒盐变异融合生物地理学 优化算法的高维多阈值分割

张新明^{1,2*}, 尹欣欣¹, 涂 强¹

(1. 河南师范大学 计算机与信息工程学院, 河南 新乡 453007;

2. 河南省高校计算智能与数据挖掘工程技术研究中心, 河南 新乡 453007)

摘要:针对高维多阈值图像分割中存在的多阈值搜索问题,提出了一种动态迁移和椒盐变异融合的生物地理学优化算法(BBOD)。首先,构建了一种基于动态扰动的迁移算子,对候选解中没有发生迁移操作的特征值添加一个动态的扰动因子,使种群的多样性增加,从而提高全局搜索能力;然后,创建了新型的变异算子,对待变异的特征值产生一个椒盐扰动,使该值在小范围内浮动,以便提高局部搜索能力和算法的收敛速度;最后,将该算法应用到基于最小交叉熵的图像高维多阈值分割中。高维多阈值分割实验结果表明,本文提出的 BBOD 算法能够获得最优的阈值向量,运行速度、性能指标均优于标准的生物地理学优化(BBO)算法,基于变异的生物地理学优化(BBOM)算法、FFA(Firefly Algorithm)和 CSA(Cuckoo Search Algorithm),运行速度是 FFA 的 5 倍以上。该算法更适用于基于最小交叉熵的高维多阈值优化选择。

关键词:图像分割;多阈值分割;优化算法;生物地理学优化算法;最小交叉熵

中图分类号:TP391.41 **文献标识码:**A **doi:**10.3788/OPE.20152310.2943

High-dimensional multilevel thresholding based on BBO with dynamic migration and salt & pepper mutation

ZHANG Xin-ming^{1,2*}, YIN Xin-xin¹, TU Qiang¹

(1. College of Computer and Information Engineering,
Henan Normal University, Xinxiang 453007, China;

2. Henan Province Engineering Technology Research Center for Computing
Intelligence & Data Mining, Xinxiang 453007, China)

* Corresponding author, E-mail: xinmingzhang@126.com.

Abstract: In view of the threshold search difficulty in high-dimensional multilevel thresholding segmentation, a Biogeography-Based Optimization with Dynamic migration and salt & pepper mutation (BBOD) was proposed. Firstly, a dynamic migration operator was created, and it could add a dynamic disturbance factor to the feature values without migration occurred in candidate solutions to increase the diversity of a population. Then, a new type of mutation operator was built to produce a salt and pepper disturbance for the feature values to be mutated, by which the local searching ability and con-

收稿日期:2015-05-19; **修订日期:**2015-07-17.

基金项目:河南省重点科技攻关计划项目(No. 132102110209);河南省基础与前沿技术研究计划项目(No. 142300410295)

vergence process of the algorithm were accelerated. Finally, the proposed BBOD algorithm was applied to the high-dimensional multilevel image thresholding segmentation based on minimum cross entropy. Experimental results show that BBOD is better in optimization performance and faster in operation speeds than standard BBO (Biogeography-Based Optimization), BBOM (Biogeography-Based Optimization with Mutation), FFA (Firefly Algorithm) and CSA (Cuckoo Search Algorithm), and its operation speed is 5 times as fast as that of FFA. The BBOD is fit to the threshold selection in the high-dimensional multilevel thresholding segmentation based on minimum cross entropy.

Key words: image segmentation; multilevel thresholding; optimization algorithm; biogeography-based optimization algorithm; minimum cross entropy

1 引言

图像分割是图像处理中十分重要的研究内容,是图像分析和图像理解等的重要前提^[1]。目前图像分割方法主要有阈值法、边缘检测法、区域分割法和基于某种特定理论的分割方法^[2,3]。其中基于图像一维灰度直方图的阈值法因计算简单、性能稳定和易于实现而被广泛应用。常用的阈值法主要有最大类间方差法^[1],最小交叉熵法^[4,5]、最大熵法^[5]等等。阈值法的关键在于找到合适的阈值,而通常采用的多阈值法在搜索阈值时因阈值数增加,计算复杂度呈指数增长,导致计算效率十分低下。为了解决这一问题,有学者提出在多阈值搜索中引入智能优化算法,以降低寻找最优阈值的计算复杂度^[6-8]。但目前对基于智能优化算法的低维(2到6维)多阈值分割问题的讨论较多,而对于6到9维的高维多阈值分割问题却由于维数较高阈值搜索困难鲜有讨论。但在实际应用中,这种高维多阈值分割问题却极为常见。

生物地理学优化(BBO)算法是一种基于群体智能的新颖的优化算法^[9],它依据生物地理学的数学模型,通过迁移和变异两种操作实现信息共享和种群进化。BBO算法结构简单,稳定性较好,已被广泛应用到许多领域中^[10-13]。但由于其迁移操作是通过直接复制候选解中的特征值实现的,所以BBO算法的搜索过程容易陷入局部最优,出现早熟现象;另外,由于变异操作采用随机变异方法,导致算法的收敛速度慢。为了提高算法的性能,许多学者进行了大量的研究,提出了一些改进算法。如Guo等人系统地分析了BBO算

法的迁移率和变异率对优化性能的影响^[14];毕晓君等人提出了一种基于动态迁移的 ϵ 约束生物地理学优化算法,并验证了其在解决约束优化问题上的有效性和先进性^[15];Ma等人在标准BBO算法的基础上,提出了3种迁移模型,并依据马尔科夫链模型进行了收敛分析^[16]。

为了提高BBO算法的优化性能,增强全局搜索能力,加快算法的收敛速度,本文针对高维多阈值分割问题提出了一种动态迁移和椒盐变异融合的BBO算法(Biogeography-Based Optimization with Dynamic migration and salt & pepper mutation, BBOD)。首先构建了一种基于动态扰动的迁移算子,增强算法的探索能力,避免出现早熟;其次创建了一种新型的变异算子,提高算法的收敛速度。

2 标准的生物地理学算法

在标准的BBO算法中,将每个栖息地作为一个候选解个体,将描述栖息地适宜度变量(Suitability Index Variables, SIVs)作为解个体中的特征变量,用栖息适宜指数(Habitat Suitability Index, HSI)来评估解个体的优劣。优质解的HSI值高,代表栖息地适宜指数高,物种种类丰富以致出现饱和,因此物种会迁出到相邻的栖息地。相反,低HSI解倾向于接受来自高HSI解的特征值。栖息地之间通过迁移和变异进行信息交换,不断改善栖息地的HSI。

BBO算法中关于栖息地之间的信息交换有两个重要的参数:栖息地的迁入率 λ_i 和迁出率 μ_i ,它们是该栖息地物种数量的函数,其计算式如下:

$$\lambda_i = I(1 - S_i/S_{\max}), \quad (1)$$

$$\mu_i = E(S_i/S_{\max}), \quad (2)$$

其中: I, E 分别表示最大迁入率和最大迁出率; S_i 表示当前种群数量, S_{\max} 表示最大种群数量。

迁移操作通过分享 HSI 较高的栖息地的特征值来改变 HSI 较低的栖息地的 SIV。迁移操作可以表示如下:

$$H_i(SIV) \leftarrow H_e(SIV), \quad (3)$$

其中: H_i 和 H_e 分别是待迁入和待迁出栖息地。

BBO 算法通过用变异算子模拟栖息地环境突变引起的物种数量变化来提高算法的探索能力。栖息地的变异概率 m_i 与其物种数量概率成反比。变异概率的计算公式如式(4)所示:

$$m_i = m_{\max}(1 - P_i/P_{\max}), \quad (4)$$

其中: m_{\max} 表示最大变异概率, $P_{\max} = \max(P_i)$, P_i 表示栖息地的物种概率, 其计算公式见文献[9]。

3 改进的生物地理学算法

3.1 动态扰动的迁移算子

标准 BBO 算法通过迁移算子进行候选解之间的信息共享, 因此具有一定的开采能力。但在迁移算子中对较低 HSI 的候选解概率性地执行迁移操作, 仅对其选中的特征值用较高 HSI 候选解的特征值代替, 对未被选中的特征值不做改变。经过迁移操作的候选解得到较优候选解的特征值, 在一定程度上提高了 HSI 值, 但提高水平有限。为了克服这一缺点, 应增强 BBO 算法的全局搜索能力、避免其陷入局部最优, 本文在标准迁移算子的基础上, 提出了一种改进的迁移算子, 即动态扰动的迁移算子。在改进的迁移算子中, 主要针对未被选中的特征值进行如下变化:

$$H_k(SIV_j) \leftarrow H_k(SIV_j) + F * (H_{r_1}(SIV_j) - H_{r_2}(SIV_j)), \quad (5)$$

$$F = F_{\max} - (F_{\max} - F_{\min}) * GenInd / GenMax, \quad (6)$$

其中: H_k 是被选中进行迁移操作的候选解, $H_k(SIV_j)$ 表示该候选解中未进行迁移操作的特征值 ($j=1, 2, \dots, d, d$ 为特征数); H_{r_1} 和 H_{r_2} 是随机选择的两个候选解, 满足 $r_1, r_2, k \in (1, 2, \dots, N, N$ 为种群数), 且三者互不相等。 $GenInd$ 表示当前种群的迭代次数, $GenMax$ 表示最大迭代次数。 F 为缩放因子, 它采用动态调整方案, F_{\max} 为缩放

因子最大值, F_{\min} 为缩放因子最小值。对候选解中没有发生迁移操作的特征值添加一个扰动因子, 从而增加了种群的多样性, 使候选解随迭代次数的增加逐渐收敛于全局最优解。而 F 的值随着迭代次数的增加逐渐减小, 使得扰动因子的幅度也随着迭代次数的增加逐渐减小, 进一步使算法向全局最优解收敛, 实现动态调整的目的。动态迁移算子伪代码见算法 1。

算法 1: 动态迁移算子

```

for k=1 to N do
  for j=1 to d do
    if rand(0,1) < λi then
      随机选择栖息地 He
      执行(3)
    else
      随机选择 r1 和 r2, 且 r1 ≠ r2 ≠ k
      执行(5)
    end
  end for
end for

```

3.2 椒盐扰动的变异算子

BBO 算法通过变异算子来模拟栖息地环境突变引起的物种数量变化, 增加栖息地物种的多样性, 可以提高算法的探索能力。然而这种模拟随机突变的变异算子无法控制其变异幅度, 尤其在搜索后期有可能会破坏较好的解, 影响算法的收敛速度。为此, 本文提出了一种椒盐扰动的变异算子见式(7):

$$H_k(SIV_p) = H_k(SIV_p) + \delta, \quad (7)$$

其中: $H_k(SIV_p)$ 表示选中第 k 个候选解的第 p ($p=1, 2, \dots, d$) 个特征值, δ 为椒盐扰动变量。椒盐扰动的概念来自数字图像处理中的“椒盐噪声”, 其能够产生一个高电平噪声干扰和一个低电平噪声干扰, 而图像分割中阈值变化的最小单位为 1 个灰度级, 所以椒盐扰动变量 δ 的取值为 1(高电平噪声干扰)或 -1(低电平噪声干扰)。式(7)表示对选中的特征值产生一个椒盐扰动, 使其值在小范围内浮动, 提高算法的局部搜索能力。在经过动态迁移操作后, 算法逐渐向全局最优解收敛, 通过椒盐扰动变异操作能够加快收敛速度, 并提高解的精度。新型变异算子伪代码如算法 2 所示。

算法 2:椒盐变异算子

```

按式(4)计算变异概率  $m_i$ 
for  $k=1$  to  $N$  do
  for  $p=1$  to  $d$  do
    if  $\text{rand}(0,1) < m_i$  then
      执行式(7)
    end if
  end for
end for

```

3.3 改进迁入率和迁出率的计算方式

在标准的 BBO 算法中,每次迭代均需要计算迁入率和迁出率,增加了计算复杂度。通过分析标准的 BBO 算法可知,只要保证适应度值为一个有效值,即保证目标函数值不会出现无穷大或无穷小等无效值,并且保证每次迭代后解集按照适宜度值进行排序,就可以在循环迭代的外面仅计算一次迁入率和迁出率,而无需对每次迭代计算迁入率和迁出率。因此,本文在保证交叉熵值不出现无效值的情况下,仅仅计算一次迁入率和迁出率来提高算法的运行速度。

4 基于 BBOD 算法的图像多阈值分割**4.1 最小交叉熵多阈值分割**

交叉熵用于度量 2 个概率分布之间的信息量差异,它分别表征分割前后图像中像素特征向量的概率分布。最小交叉熵阈值分割方法通过求最优阈值使原始图像和分割图像之间的信息量差异最小。最小交叉熵多阈值分割方法^[6]描述如下:设一幅图像的灰度级数为 L (L 通常取 256),则其图像灰度取值为 $[1, L]$ 。灰度值为 i 出现的概率为 $h(i)$,其中 $i=1, 2, 3, \dots, L$ 。对于一组任意给定的阈值 x_1, x_2, \dots, x_d ,且 $(1 < x_1 < x_2 < \dots < x_d < L)$,将图像分割为 $d+1$ 个部分,每一部分的交叉熵如式(8)~式(10)所示:

$$E_0 = \sum_{i=1}^{x_1-1} ih(i) \log(i/u(1, x_1)), \quad (8)$$

$$E_1 = \sum_{i=x_1}^{x_2-1} ih(i) \log(i/u(x_1, x_2)), \quad (9)$$

.....,

$$E_d = \sum_{i=x_d}^L ih(i) \log(i/u(x_d, L)), \quad (10)$$

其中: d 为阈值数, $u(1, x_1)$ 和 $u(x_1, x_2)$ 分别表示各区域的类内均值,如式(11)所示:

$$u(a, b) = \sum_{i=a}^{b-1} ih(i) / \sum_{i=a}^{b-1} h(i), \quad (11)$$

则总的交叉熵^[6]为:

$$CE(x_1, x_2, \dots, x_d) = \sum_{i=1}^L ih(i) \log(i) - (E_0 + E_1 + \dots + E_d). \quad (12)$$

待分割图像的最佳阈值向量是使 $CE(x_1, x_2, \dots, x_d)$ 取得最小值的一组阈值:

$$(x_1^*, x_2^*, \dots, x_d^*) = \arg \min \{ CE(x_1, x_2, \dots, x_d) \}. \quad (13)$$

4.2 BBOD 算法在图像多阈值分割中的应用

假设对一幅图像进行 d 阈值分割,则解向量为 $\mathbf{x}=[x_1, x_2, \dots, x_d]$,其分量取值为正整数并且满足 $1 < x_1 < x_2 < \dots < x_d < L$ 。以最小交叉熵法则作为分割准则,在解空间 L 个灰度级之间采用 BBOD 算法进行优化选择,满足式(13)的一组解向量即为最优解。将式(12)作为衡量各个解 HSI 的目标函数,候选解相当于 BBOD 算法中的栖息地,解向量中的阈值相当于栖息地的特征量。基于 BBOD 算法的图像多阈值分割方法的步骤如下:

Step 1:读入图片,参数初始化。设最大迭代次数为 $GenMax$,种群数量为 N ,阈值个数为 d ;

Step 2:随机生成初始化种群 \mathbf{X} , \mathbf{X} 为 N 行 d 列正整数矩阵,将 \mathbf{X} 每行按从小到大的顺序排序,以满足阈值向量要求;

Step 3:用式(12)评估每个栖息地 X_i 的 HSI, ($i=1, \dots, N$),依据 HSI 值对 X_i 按照升序排序,并根据式(1)和式(2)计算迁入率和迁出率;

Step 4:保留解集中前 C 个较优的解;

Step 5:执行算法 1 的动态迁移操作;

Step 6:执行算法 2 的椒盐变异操作;

Step 7:将新一代栖息地 X_{new_i} 的特征值从小到大排序,以便符合阈值解向量的要求,用式(12)评估其 HSI, ($i=1, \dots, N$);

Step 8:用保留的 C 个精英解替换新一代解集 X_{new} 中较差的解;

Step 9:依据 HSI 值对 X_i 按照升序排序;

Step 10:若没有达到停止准则,转到 Step 4;

Step 11:用求得的最优阈值进行图像分割,并输出分割结果。


从以上算法可以看出:迁入率和迁出率仅仅计算一次,有利于降低计算复杂度。

5 实验结果与分析

为了检验基于 BBOD 算法的最小交叉熵高

维多阈值搜索方法的有效性,进行了多阈值搜索实验,并将实验结果与基于标准 BBO 算法^[9]、BBOM (Biogeography-Based Optimization algorithm with Mutation)算法^[13]、FFA (Firefly Algorithm)^[6,7] 和 CSA (Cuckoo Search Algorithm)^[8]的最小交叉熵高维多阈值搜索方法的结果进行比较。其中, BBOM 是 2014 年由 Niu 等人提出的 BBO 算法改进版, FFA 和 CSA 分别是近年来提出的萤火虫算法和布谷鸟搜索算法,这 3 种算法都是 state-of-the-art 算法,据相关文献报道它们的优化性能优于遗传算法、粒子群算法等传统优化算法。限于篇幅,本文仅使用两幅图片 House.png (256 * 256) 和 Flame.png (134 * 222) 作为示例,原图像和其多阈值分割结果见图 1(彩图见期刊电子版)和图 2(彩图见期刊电子版)。为了凸显分割的结果,本文采用假彩色表示,不同的颜色代表不同的分割区域。这两幅图片都是实际采集的,前者为现实生活中的房屋图片,后者为发电厂锅炉燃烧的火焰图片。从分割


图可以看出高维多阈值分割方法能将图像更多的细节区域,甚至将人眼难以观察到的区域分割出来,如图 2 的火焰分割结果图所示,而火焰图像的准确分割对于进一步提取锅炉燃烧工况参数和后续的状态识别具有重要意义。所有实验均在 CPU 主频 3.4GHz 的 Intel Core(TM) i7-3770 和内存 8GB 的 PC 上进行,操作系统采用 Windows 7,编程语言采用 MATLAB R2014a。为了公平起见,每种算法的种群大小都设置为 20,最大迭代次数设置相同,为了满足不同阈值选择的需要,使最大迭代次数(GenMax)随着阈值数 d 的增加而增加,以便达到自动调整 GenMax 的目的,即 $GenMax = 2d^2 + 20(d - 1) + 12$ 。FFA 和 CSA 的其它参数设置分别见文献[6]和文献[8]。而标准 BBO 算法和 BBOM 算法其它参数设置相同:最大迁入率(I)为 1,最大迁出率(E)为 1,精英保留数 C 为 2,最大变异率为 0.05。BBOD 算法新增加的参数设置如下: $F_{max} = 1, F_{min} = 0.01$,其它参数设置同 BBO 算法。



(a) House 原图 (b) 6 阈值结果 (c) 7 阈值结果 (d) 8 阈值结果 (e) 9 阈值结果
 (a) House image (b) 6-threshold result (c) 7-threshold result (d) 8-threshold result (e) 9-threshold result

图 1 House 图片及其多阈值分割结果

Fig. 1 House image and its segmented results by multilevel thresholds



(a) Flame 原图 (b) 6 阈值结果 (c) 7 阈值结果 (d) 8 阈值结果 (e) 9 阈值结果
 (a) Flame image (b) 6-threshold result (c) 7-threshold result (d) 8-threshold result (e) 9-threshold result

图 2 Flame 图片及其多阈值分割结果

Fig. 2 Flame image and its segmented results by multilevel thresholds

实验 1 优化性能比较。为了评价 5 种优化算法的性能,将 5 种优化算法用于两幅图像的交叉熵多阈值搜索中,并独立运行 50 次,选取 50 次中的最大值 Max(最差值),平均值 Mean,方差 Std,最小值 Min(最好值)、算法的成功次数(Number of Successes, NS)及运行时间(Time)作为评价标准来考察它们的优化性能。其中,一种算法的成功次数是以 V_{op} 作为评价参考,即独立运行 50 次,该算法寻找的最优值为 V_{op} 的次数;而 V_{op} 为 5 种算法在同一图像、同一阈值数上共运行 50×5 次中搜索到的最小交叉熵值。 V_{op} 及其对应的最优阈值组合见表 1。为了凸显本文算法较强的寻优能力,仅提供其在 6, 7, 8 和 9 阈值的高维优化情况,5 种优化算法用于 House 和 Flame 两幅图像的优化搜索结果分别如表 2 和表 3 所示,其中优者用黑体表示。

表 1 两幅图像的最小交叉熵和其对应的最优阈值组合

Tab. 1 Minimum cross entropy values and corresponding optimal thresholds of two images

Images	d	Optimal thresholds	V_{op}
House	6	56, 81, 104, 127, 158, 195	0.157 74
	7	50, 68, 85, 105, 128, 158, 195	0.123 97
	8	49, 67, 84, 102, 115, 132, 160, 195	0.097 34
	9	42, 58, 72, 86, 102, 115, 132, 160, 195	0.079 31
Flame	6	19, 34, 58, 102, 161, 217	0.290 85
	7	18, 30, 46, 70, 110, 164, 218	0.228 76
	8	17, 28, 42, 64, 99, 143, 185, 225	0.179 03
	9	16, 25, 35, 49, 71, 103, 144, 185, 225	0.146 58

从表 2 和表 3 可以看出,本文提出的 BBOD 算法在图像的 6, 7, 8 和 9 阈值搜索中都能获得最优阈值向量,而且 BBOD 得到的交叉熵最大值、均值和方差都最小;CSA 和 BBOM 在图像的 6 至 9 阈值搜索的 50 次运行中都能够取得最优阈值向量,但其均值、方差和最大值都不及 BBOD 算法。标准的 BBO 算法和 FFA 算法(除了 Flame 图片的 6 阈值外)搜索得到的交叉熵值虽然接近最优值,但不是最优值。由此可知, BBOD 算法在基于最小交叉熵高维多阈值搜索中,能够成功获得全局最优解,并且其优化性能大幅度优于 BBO 算法,这是因为 BBOD 算法通过动态扰

表 2 5 种优化算法对 House 图像阈值搜索结果对比

Tab. 2 Comparison of threshold searching results among 5 optimization algorithms on House image

d	Method	Std	Mean	Max	Min	NS
6	BBO	5.7918e-3	0.160 80	0.198 61	0.157 77	0
	BBOM	1.3789e-2	0.161 61	0.229 21	0.157 74	46
	FFA	2.5319e-2	0.177 71	0.265 58	0.157 77	0
	CSA	2.3258e-5	0.157 74	0.157 90	0.157 74	47
	BBOD	0	0.157 74	0.157 74	0.157 74	50
7	BBO	2.2310e-3	0.126 94	0.133 55	0.124 11	0
	BBOM	7.1454e-3	0.127 13	0.150 19	0.123 97	30
	FFA	1.4669e-2	0.148 63	0.178 81	0.126 11	0
	CSA	7.3956e-4	0.124 12	0.128 76	0.123 97	35
	BBOD	0	0.123 97	0.123 97	0.123 97	50
8	BBO	2.6955e-3	0.099 92	0.105 34	0.097 57	0
	BBOM	8.1366e-3	0.102 61	0.121 28	0.097 34	31
	FFA	1.1254e-2	0.125 02	0.163 41	0.098 74	0
	CSA	8.2017e-5	0.097 37	0.097 85	0.097 34	39
9	BBOD	0	0.097 34	0.097 34	0.097 34	50
	BBO	1.6628e-3	0.080 64	0.086 27	0.079 37	0
	BBOM	5.3399e-3	0.083 41	0.096 96	0.079 31	24
	FFA	9.7298e-3	0.107 43	0.138 91	0.092 62	0
	CSA	2.6579e-3	0.080 12	0.089 99	0.079 31	19
BBOD	0	0.079 31	0.079 31	0.079 31	50	

表 3 5 种优化算法对 Flame 图像阈值搜索结果对比

Tab. 3 Comparison of threshold searching results among 5 optimization algorithms on Flame image

D	Method	Std	Mean	Max	Min	NS
6	BBO	1.4999e-2	0.302 29	0.368 66	0.291 33	0
	BBO M	5.6172e-3	0.292 06	0.319 77	0.290 85	46
	FFA	2.5388e-2	0.315 66	0.365 23	0.290 85	1
	CSA	1.5612e-5	0.290 86	0.290 96	0.290 85	43
	BBOD	0	0.290 85	0.290 85	0.290 85	50
7	BBO	5.2410e-3	0.236 05	0.249 34	0.230 13	0
	BBOM	2.6481e-3	0.230 62	0.234 46	0.228 76	28
	FFA	7.7091e-3	0.240 20	0.264 51	0.230 46	0
	CSA	1.3649e-3	0.229 16	0.234 43	0.228 76	35
	BBOD	1.3601e-3	0.229 10	0.234 43	0.228 76	47
8	BBO	7.0179e-3	0.184 23	0.211 50	0.179 17	0
	BBOM	2.0877e-3	0.179 59	0.189 88	0.179 03	13
	FFA	1.2395e-2	0.197 88	0.225 29	0.179 22	0
	CSA	2.8210e-4	0.179 10	0.181 04	0.179 03	15
	BBOD	1.7905e-5	0.179 03	0.179 07	0.179 03	41
9	BBO	5.3635e-3	0.154 06	0.164 02	0.146 66	0
	BBOM	5.0891e-3	0.150 90	0.160 27	0.146 58	18
	FFA	5.6327e-3	0.163 65	0.179 06	0.152 03	0
	CSA	2.6944e-3	0.147 48	0.156 79	0.146 58	24
	BBOD	1.3788e-3	0.146 77	0.156 33	0.146 58	49

动的迁移算子增加种群的多样性,从而增强了算法的全局搜索能力,又通过椒盐变异算子提高了算法局部搜索能力。从成功率看,对于 House 图像, BBOD 算法在 4 种阈值搜索中,寻得最优阈值的成功率都为 100%;对于 Flame 图像, BBOD 算法在 6 阈值搜索中的成功率为 100%,在 7,8 和 9 阈值搜索的成功率分别为 94%、82%和 98%。其它 4 种算法的成功率低,都大幅度低于 BBOD 算法。此外, BBOD 算法的寻优成功率没有达到 100%的阈值搜索,与其它 4 种算法相比,其获得的最好与最差交叉熵值之间的差距小,说明其稳定性较好。

实验 2 5 种优化算法阈值搜索时间比较。表 4 是 5 种优化算法对于两幅图像在不同的阈值搜索中的耗时,其中 H 和 F 分别表示 House 图像和 Flame 图像, FEVs 表示目标函数运行的次数。从表 4 可以看出,与 BBO 算法相比, BBOD 算法的运行时间少,这是由于改进的迁入率和迁出率计算方式降低了计算复杂度;它也是 5 种算法里运行时间最少的算法,见表 4 的最后一列,大约是 FFA 的 20%,其次是 CSA,再其次是 BBOM 算法。FFA 算法的耗时最多,见表 4 的倒数第三列最后一行,这是因为 FFA 在每一代都要计算萤火虫之间的欧式距离,而这种计算需要大量的时间。虽然 CSA、BBO 和 BBOM 算法的耗时与 BBOD 算法相差不大,但在处理大量的图片分割中,尤其在大数据时代, BBOD 算法耗时少的优越性将更加凸显。将表 4 与表 2 和表 3 结合起来分析,结果显示在同样的 FEVs 下, BBOD 能够找到最优解,且成功率高,这说明本文算法的收敛速度快。

表 4 5 种优化算法运行时间对比

Tab. 4 Running time comparison among 5 optimization algorithms (s)

d / FEVs	I	BBO	BBOM	FFA	CSA	BBOD
6 / 3700	H	0.068 4	0.068 4	0.284 4	0.057 9	0.054 5
	F	0.068 0	0.068 5	0.290 9	0.066 4	0.054 9
7 / 4620	H	0.097 1	0.087 7	0.390 5	0.073 3	0.070 0
	F	0.087 1	0.088 0	0.368 1	0.074 2	0.070 4
8 / 5620	H	0.111 9	0.110 1	0.456 8	0.090 7	0.086 5
	F	0.109 2	0.111 0	0.457 4	0.090 6	0.086 6
9 / 6700	H	0.138 5	0.134 9	0.548 8	0.111 5	0.105 0
	F	0.134 9	0.134 1	0.552 0	0.107 5	0.104 2
Average Time		0.101 9	0.100 3	0.418 6	0.084 0	0.079 0

实验 3 缩放因子 F 对 BBOD 算法优化性能的影响。在 BBOD 算法中,新增了参数缩放因子 F,它是影响优化性能的最主要参数,而其他参数在目前 BBO 算法的相关文献中已作讨论^[17]。为了研究 F 对算法性能的影响,将参数 F 分别取为 F=0.1、F=0.3、F=0.5 和 F=0.7,并与 F 的动态调整(Dynamical Modulation, DM)方案进行比较。限于篇幅,仅使用 House 图像进行实验。在其它参数不变的情况下, BBOD 算法独立运行 50 次,得到 6,7,8 和 9 阈值搜索的最大值 Max,平均值 Mean,方差 Std,最小值 Min、算法的成功次数 NS,结果见表 5。从表 5 可以看出:在 6 阈值搜索中, F=0.3 和 F=0.5 以及 DM 的情况下,获得的优化效果最好,成功率都为 100%,而在其他阈值搜索中,不管从获取的最优值,最差值,平均值和方差,还是成功次数,动态调整获得的效果都最好。例如在 7,8 和 9 阈值中, BBOD 算法在 F 为动态调整方案下获得的成功次数都为 50,成功率为 100%,大幅度优于 F=0.1、F=0.3、F=0.5 和 F=0.7 时的结果, F=0.7 的优化效果最差。这说明采用动态调整缩放因子方案可行,建议使用这种动态调整方案。

表 5 参数 F 对 House 图像阈值搜索结果的影响

Tab. 5 Influence of F on threshold searching results for House image

d	F	Std	Mean	Max	Min	NS
6	0.1	1.1509e-2	0.159 98	0.229 09	0.157 74	48
	0.3	0	0.157 74	0.157 74	0.157 74	50
	0.5	0	0.157 74	0.157 74	0.157 74	50
	0.7	7.3572e-6	0.157 74	0.157 77	0.157 74	43
	DM	0	0.157 74	0.157 74	0.157 74	50
7	0.1	9.4182e-3	0.129 31	0.150 19	0.123 97	30
	0.3	6.3428e-3	0.126 50	0.150 19	0.123 97	37
	0.5	4.1549e-3	0.126 22	0.150 19	0.123 97	28
	0.7	1.5673e-3	0.124 57	0.128 78	0.123 97	18
	DM	0	0.123 97	0.123 97	0.123 97	50
8	0.1	9.5998e-3	0.105 31	0.121 28	0.097 34	28
	0.3	9.5977e-3	0.104 12	0.121 28	0.097 34	33
	0.5	8.3033e-3	0.101 17	0.121 31	0.097 34	35
	0.7	4.6419e-5	0.097 40	0.097 51	0.097 34	13
	DM	0	0.097 34	0.097 34	0.097 34	50
9	0.1	7.1570e-3	0.087 03	0.113 12	0.079 31	19
	0.3	5.5682e-3	0.084 31	0.097 04	0.079 31	27
	0.5	5.3256e-3	0.084 63	0.089 93	0.079 31	7
	0.7	3.4811e-3	0.081 07	0.090 23	0.079 31	1
	DM	0	0.079 31	0.079 31	0.079 31	50

综上所述,在最小交叉熵的高维多阈值分割中,与 BBO、FFA 和 CSA 相比,BBOD 算法能够快速收敛到全局最优值,搜索成功率高,且稳定性好。

6 结 论

本文针对高维多阈值分割问题提出了一种 BBOD 算法,它通过采用动态扰动的迁移算子和

椒盐扰动的变异算子,增强了算法的全局搜索能力,提高了收敛速度。将 BBOD 算法应用到基于最小交叉熵的高维多阈值分割中的实验结果表明,本文提出的 BBOD 算法在图像高维多阈值分割中,能够获得最优的阈值向量,且搜索速度快,是 FFA 的 5 倍以上,稳定性好,成功率高。BBOD 算法更适用于基于最小交叉熵的高维多阈值优化选择。

参考文献:


- [1] 何志勇,孙立宁,黄伟国,等.基于 Otsu 准则和直线截距直方图的阈值分割[J].光学精密工程,2012,20(10):2315-2323.
HE ZH Y, SUN L N, HUANG W G, *et al.*. Thresholding segmentation algorithm based on Otsu criterion and line intercept histogram [J]. *Opt. Precision Eng.*, 2012,20(10):2315-2323. (in Chinese)
- [2] 王冬冬,张炜,金国锋,等.尖点突变理论在红外热波检测图像分割中的应用[J].红外与激光工程,2014,43(3):1009-1015.
WANG D D, ZHANG W, JIN G F, *et al.*. Application of cusp catastrophic theory in image segmentation of infrared thermal waving inspection [J]. *Infrared and Laser Engineering*, 2014, 43(3):1009-1015. (in Chinese)
- [3] 李晓峰,徐军,罗积军,等.基于 Contourlet 域 HMT-3S 模型的激光主动成像图像分割[J].红外与激光工程,2012,41(2):531-536.
LI X F, XU J, LUO J J, *et al.*. Laser active image segmentation based on Contourlet-domain hidden Markov trees-3S model [J]. *Infrared and Laser Engineering*, 2012, 41(2):531-536. (in Chinese)
- [4] CHEN X W, KAR S, RALESCU D A. Cross-entropy measure of uncertain variables[J]. *Information Sciences*, 2012, 201:53-60.
- [5] 张新明,孙印杰,张慧云.最大熵和最小交叉熵综合的交互式图像分割[J].计算机工程与应用,2010,46(30):191-194.
ZHANG X M, SUN Y J, ZHANG H Y. Interactive image segmentation based on combining maximum entropy and minimum cross entropy [J]. *Computer Engineering and Applications*, 2010, 46(30):191-194. (in Chinese)
- [6] HORNG M H, LIOU R J. Multilevel minimum cross entropy threshold selection based on the firefly algorithm [J]. *Expert Systems with Application*, 2011, 38(12):14805-14811.
- [7] 陈恺,陈芳,戴敏,等.基于萤火虫算法的二维多阈值快速图像分割[J].光学精密工程,2014,22(2):517-523.
CHEN K, CHEN F, DAI M, *et al.*. Fast image segmentation with multilevel threshold of two-dimensional entropy based on firefly algorithm [J]. *Opt. Precision Eng.*, 2014, 22(2):517-523. (in Chinese)
- [8] BHANDARI A K, SINGH V K, KUMAR A, *et al.*. Cuckoo search algorithm and wind driven optimization based study of satellite image segmentation for multilevel thresholding using Kapur's entropy [J]. *Expert Systems with Application*, 2014, 41(7):3538-3560.
- [9] SIMON D. Biogeography-based optimization [J]. *IEEE Transaction on Evolutionary Computation*, 2008,12(6):702-713.
- [10] YANG G Q, LIU Y K, YANG K. Multi-objective biogeography-based optimization for supply chain network design under uncertainty[J]. *Computers and Industrial Engineering*, 2015, 85:145-156.
- [11] TAMJIDY M, PASLAR S, BAHARUDIN B T, *et al.*. Biogeography based optimization (BBO) algorithm to minimize non-productive time during hole-making process[J]. *International Journal of Production Research*, 2015, 53(6):1880-1894.
- [12] KIM S S, BYEON J H, YU H, *et al.*. Biogeography-based optimization for optimal job scheduling in cloud computing [J]. *Applied Mathematics and Computation*, 2014, 247:266-280.
- [13] NIU Q, ZHANG L T, LI K. A biogeography-based optimization algorithm with mutation strate-

- gies for model parameter estimation of solar and fuel cells [J]. *Energy Conversion and Management*, 2014, 86: 1173-1185.
- [14] GUO W A, WANG L, WU Q D. An analysis of the migration rates for biogeography-based optimization[J]. *Information Sciences*, 2014, 254:111-140.
- [15] 毕晓君, 王珏, 李博, 等. 基于动态迁移的 ϵ 约束生物地理学优化算法[J]. *计算机研究与发展*, 2014, 51(3): 580-589.
- BI X J, WANG J, LI B, *et al.*. An ϵ constrained biogeography-based optimization with dynamic migration[J]. *Journal of Computer Research and Development*, 2014, 51(3): 580-589. (in Chinese)
- [16] MA H P, SIMON D, FEI M R, *et al.*. Variations of biogeography- based optimization and Markov analysis [J]. *Information Sciences*, 2013, 220: 492-506.
- [17] MA H P. An analysis of the equilibrium of migration models for biogeography-based optimization [J]. *Information Sciences*, 2010, 180(18):3444-3464.

作者简介:



张新明(1963—),男,湖北孝感人,教授,硕士生导师,2005年于湖北大学获得硕士学位,主要从事智能优化算法、数字图像处理和模式识别等方面的研究, E-mail: xinmingzhang@126.com.



尹欣欣(1990—),女,河南安阳人,硕士研究生,2013年于河南师范大学获得学士学位,主要从事图像分割和智能优化算法的研究, E-mail: 497351999@qq.com.

(版权所有 未经许可 不得转载)