

基于混沌飞蛾扑火优化的膝盖 MRI 分割算法

王海芳, 祁超飞, 张 瑶, 朱亚锸
(东北大学秦皇岛分校 控制工程学院, 河北 秦皇岛 066004)

摘 要: 由于飞蛾扑火优化(MFO)算法在解决实际优化问题时仍会表现出易陷局部最优、收敛停滞等不足,针对 MRI 图像较难分割问题,本文提出了一种基于混沌飞蛾扑火(CMFO)的膝盖 MRI 分割算法. 为辅助医生阅片,提高诊断效率和准确率,实验先将膝盖 MRI 图像选作研究对象,然后将 CMFO 算法与最大阈值熵相结合应用到医学 MRI 图像多阈值分割领域. 为突出基于 CMFO 的膝盖 MRI 分割的优势,引入了 SOA, BFOA 和 MFO 算法作对比实验,结果表明:CMFO 算法能有效改善 MFO 的优化性能,而且对膝盖 MRI 图像分割具有更好的适用性和优越性.

关 键 词: 混沌策略;膝盖 MRI 图像;最大阈值熵;多阈值分割;飞蛾扑火优化

中图分类号: TG 391.41 **文献标志码:** A **文章编号:** 1005-3026(2020)03-0326-06

Knee MRI Segmentation Algorithm Based on Chaotic Moth-Flame Optimization

WANG Hai-fang, QI Chao-fei, ZHANG Yao, ZHU Ya-kun
(School of Control Engineering, Northeastern University at Qinhuangdao, Qinhuangdao 066004, China.
Corresponding author: WANG Hai-fang, E-mail: hfwang@neuq.edu.cn)

Abstract: The moth-flame optimization (MFO) algorithm may show shortcomings such as the local optimum and convergence stagnation when solving the practical optimization problem. Therefore, aiming at the problem that MRI (magnetic resonance imaging) images are difficult to segment, this paper proposes a chaotic moth-flame optimization (CMFO) algorithm. In order to help doctors read the MRI films and improve the efficiency and accuracy of diagnosis, the knee MRI images are selected as research objects during the experiments. Then, CMFO algorithm and maximum threshold entropy are combined and applied into multi-threshold segmentation. In order to present the advantages of the CMFO algorithm proposed, SOA, BFOA and MFO algorithms are introduced under the same condition for comparative experiments. The experimental results show that CMFO can effectively improve the optimal performance of MFO, and has better applicability and advantages for knee MRI image segmentation.

Key words: chaotic strategy; knee MRI image; maximum threshold entropy; multilevel-threshold segmentation; moth-flame optimization (MFO)

MRI(磁共振成像)技术^[1]在磁场中对人体进行局部扫描时可以根据原子核共振获取人体不同部位电磁信号,然后重建成像,目前是一种重要的医学影像诊断方法;同时 MRI 技术获取的实时影像能够提取出更多人体不同部位的真实信息,特别在疾病诊断方面具有很大的潜在优势.但目前 MRI 医学影像较复杂而且图像特异性还不够理想,病理组织重叠较多,磁共振信号一般比较接近.所以,对 MRI 图像进行适当的分割很有必要,有助于降低依据 MRI 成像来对病变定性判断的风险,协助做出更确切的诊断.为了提高诊断效率和准确率,帮助医生获取 MRI 实时影像中更多人体不同部位的真实信息,故需要对人体实时 MRI 影像中目标部位有效信息进行尽量精确的分割处

理. 因此, 本文以膝盖 MRI 图像^[2]为例, 以计算图像最大熵作分割依据进行多阈值分割, 对实时获取的人体膝盖 MRI 图像进行分割操作. 传统分割方法^[3]虽然也可以但分割效果不是非常理想, 通常很难满足 MRI 图像分析的精度要求. 采用群智能优化算子^[4]对图像进行分割优化可在一定程度上提高 MRI 图像分割质量. 作为通过模仿飞蛾横向定位飞行特点而提出的一种新颖的、可扩展性好、鲁棒性强等诸多优点的群智能优化算法, 飞蛾扑火优化 (MFO) 算法^[5]能够很大程度地提高 MRI 图像分割精度. 鉴于 MFO 算法可能存在收敛停滞、易陷局部最优等不足, 为了最大程度上弥补 MFO 本身的不足, 本文针对 MRI 图像提出一种基于混沌飞蛾扑火 (CMFO) 的膝盖 MRI 图像分割算法, 实验证明了本文 MRI 分割方法的有效性.

1 飞蛾扑火优化算法与最大阈值熵

1.1 飞蛾扑火优化算法

飞蛾扑火优化 (MFO)^[6] 算法最初是由 Mirjalili 提出的. 当采用 MFO 算法解决实际问题时, 飞蛾本身代表拟解决问题的解, 而本文用飞蛾实际的空间位置代表该问题的实际变量. 飞蛾种群 M 实际的空间位置可用 $N \times \text{DIM}$ 维矩阵来表示. 在该矩阵中 DIM 表示飞蛾空间位置的维度 (dimension), N 表示飞蛾的数量. 飞蛾可以通过改变其自身的位置矢量在一维、二维、三维甚至超维空间飞行. 飞蛾适应度 om 表示为 $[\text{om}_1, \text{om}_2, \dots, \text{om}_N]$, 其储存 MFO 种群中每个飞蛾目标函数的返回值. 火焰也是 MFO 的主要结构, 火焰矩阵 F 具有与飞蛾矩阵 M 相同大小的维度, 火焰也通过 1 个数组来保存适应度值 of . 同理, 火焰适应度值可存储为

$$\text{of} = [\text{of}_1, \text{of}_2, \dots, \text{of}_N]. \quad (1)$$

火焰矩阵可以表示为

$$F = \begin{bmatrix} f_{1,1} & f_{1,2} & \cdots & f_{1,\text{DIM}} \\ f_{2,1} & f_{2,2} & \cdots & f_{2,\text{DIM}} \\ \vdots & \vdots & \vdots & \vdots \\ f_{N,1} & f_{N,2} & \cdots & f_{N,\text{DIM}} \end{bmatrix}. \quad (2)$$

MFO 算法具有一个模拟全局优化的三元组模型:

$$\text{MFO} = (I, P, T). \quad (3)$$

其中 I 为生成初代飞蛾的函数,

$$I = \phi = \{M, \text{om}\}. \quad (4)$$

其中: $M(i, j) = (\text{UB}(i) - \text{LB}(i)) / \text{rand}() + \text{LB}(i)$;

$$\text{om} = \text{FitnessFunction}(M);$$

$$\text{UB} = [\text{ub}_1, \text{ub}_2, \text{ub}_3, \dots, \text{ub}_{N-1}, \text{ub}_N];$$

$$\text{LB} = [\text{lb}_1, \text{lb}_2, \text{lb}_3, \dots, \text{lb}_{N-1}, \text{lb}_N].$$

P 是 MFO 算法三元组模型的更新法则, 表示在区域中更新 M 矩阵: $M \rightarrow M$; T 表示该模型判断法则, 满足终止条件的返回 ture , 否则返回 false :

$$T: M \rightarrow \{\text{ture}, \text{false}\}. \quad (5)$$

为了模仿飞蛾的横向飞行定位方式, 飞蛾实时位置可按式进行更新:

$$M_i = S(M_i, F_j). \quad (6)$$

式中: S 代表螺旋函数; M_i 表示 MFO 中第 i 只飞蛾; F_j 为 MFO 中第 j 簇火焰, 同时三者满足下式:

$$S(M_i, F_j) = D_i \cdot e^{bt} \cdot \cos(2\pi t) + F_j. \quad (7)$$

其中: D_i 是第 M_i 只飞蛾到第 F_j 个火焰的间距, $D_i = |F_j - M_i|$; b 为 MFO 中飞蛾实际螺旋方向飞行常数; t 为自适应收敛常数, 为一个落在 $[-1, 1]$ 内的随机数.

1.2 图像最大阈值熵

当按照某一特定阈值 q ($0 \leq q < K-1$) 进行分割, 其中 $K=256$ 时, 目标图像可分为 2 个图像区域 C_0, C_1 , 其概率密度函数为

$$C_0: \left(\frac{p(0)}{P_0(q)}, \frac{p(1)}{P_0(q)}, \frac{p(2)}{P_0(q)}, \dots, \frac{p(q)}{P_0(q)}, 0, \dots, 0 \right); \quad (8)$$

$$C_1: \left(0, 0, \dots, 0, \frac{p(q+1)}{P_1(q)}, \frac{p(q+2)}{P_1(q)}, \dots, \frac{p(K-1)}{P_1(q)} \right). \quad (9)$$

$$P_0(q) = \sum_{i=0}^q p(i) = P(q),$$

$$P_1(q) = \sum_{i=q+1}^{K-1} p(i) = 1 - P(q). \quad (10)$$

式中, $P_0(q), P_1(q)$ 分别表示 q 阈值分割下的背景和前景像素累积概率, 且两者之和为 1. $H_0(q)$ 和 $H_1(q)$ 分别表示图像背景熵和前景熵, 则在该阈值下的图像最大阈值熵^[7-8]为

$$\begin{aligned} \text{KSW}(q) &= H_0(q) + H_1(q) = \\ &= - \sum_{i=0}^q \frac{p(i)}{P_0(q)} \lg\left(\frac{p(i)}{P_0(q)}\right) - \sum_{i=q+1}^{K-1} \frac{p(i)}{P_1(q)} \lg\left(\frac{p(i)}{P_1(q)}\right). \end{aligned} \quad (11)$$

若按照 DIM 个阈值进行分割, 则原图像可分割成 $\text{DIM}+1$ 个区域, 图像最大阈值熵公式为

$$\text{KSW}(q_{\text{DIM}}) = \max(H_0(q) + H_1(q) + \dots + H_{\text{DIM}}(q)). \quad (12)$$

2 混沌策略与图像质量评价指标

2.1 混沌优化搜索策略^[9]及分割算法流程图

图 1 为分割算法流程图,图中取第 $iter$ 次迭代过程中飞蛾群体中全局适应度值最优 g_{best} 的那一组飞蛾个体的位置为 $M_{g_{best}}^{iter}$,其表示如下:

$$M_{g_{best}}^{iter} = (M_{g_{best1}}^{iter}, M_{g_{best2}}^{iter}, \dots, M_{g_{bestd}}^{iter}, \dots, M_{g_{bestDIM}}^{iter}). \quad (13)$$

步骤 1 按照式(14)将当前最优飞蛾个体位置的每一维映射到区间 $(-1, 1)$ 内, $d \in [1, DIM]$:

$$N_{g_{bestd}}^{iter} = \frac{2(M_{g_{bestd}}^{iter} - M_{mind}^{iter})}{M_{maxd}^{iter} - M_{mind}^{iter}} - 1. \quad (14)$$

步骤 2 将映射后最优飞蛾个体变量 $N_{g_{bestd}}^{iter}$ 代入如下的逻辑自映射函数中进行 CN 次迭代并得到混沌序列:

$$N_{g_{bestd}}^{t_c} = 1 - 2 \cdot (N_{g_{bestd}}^{t_c-1})^2; \quad (15)$$

其中:CN 为迭代次数; $t_c = 1, 2, \dots, CN + 1$;

$$N_{g_{bestd}}^{t_c} \in (-1, 1), N_{g_{bestd}}^0 = N_{g_{bestd}}^{iter}.$$

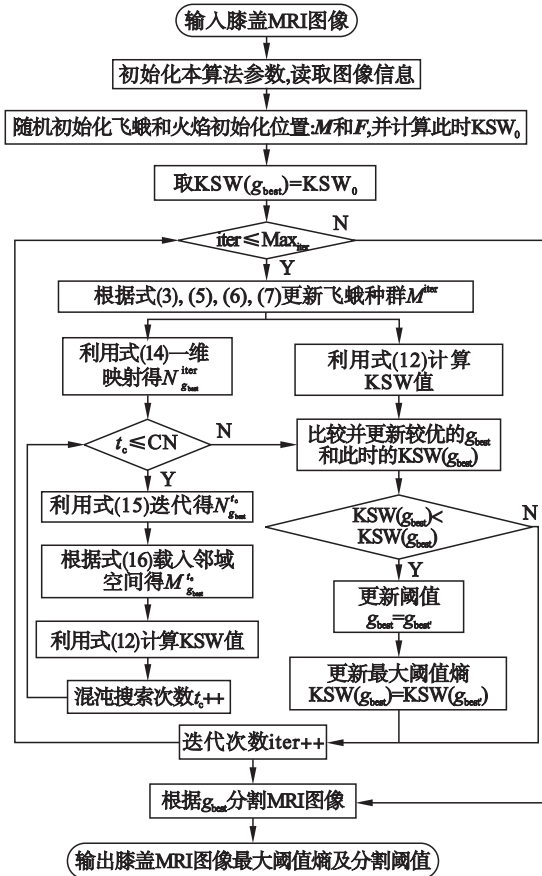


图 1 本分割算法流程图

Fig. 1 Flowchart of the segmentation algorithm

步骤 3 利用式(16)将 $N_{g_{bestd}}^{t_c}$ 载入到邻域空

间中,从而生成新飞蛾位置:

$$M_{g_{bestd}}^{t_c} = \frac{1}{2} (M_{maxd}^{iter} - M_{mind}^{iter}) \cdot N_{g_{bestd}}^{t_c} + \frac{1}{2} (M_{maxd}^{iter} - M_{mind}^{iter}). \quad (16)$$

步骤 4 分别计算 $M_{g_{bestd}}^{t_c}$ 和 $M_{g_{best}}^{iter}$ 对应的适应值,然后更新当前飞蛾的最优位置。

步骤 5 判断当前混沌搜索是否达到预期最大次数,然后选择终止搜索或执行步骤 2。

2.2 图像质量评价指标

1) 峰值信噪比 PSNR:

$$MSE = \frac{1}{mn} \sum_{x=0}^{m-1} \sum_{y=0}^{n-1} \|I(x, y) - K(x, y)\|^2; \quad (17)$$

$$PSNR = 10 \cdot \lg\left(\frac{MAX_I^2}{MSE}\right) = 20 \cdot \lg\left(\frac{MAX_I}{\sqrt{MSE}}\right). \quad (18)$$

2) 结构相似性 SSIM:

$$SSIM(x, y) = [I(x, y)]^\alpha [c(x, y)]^\beta [s(x, y)]^\gamma = \frac{(2\mu_x\mu_y + c_1)(2\sigma_x\sigma_y + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)}. \quad (19)$$

3) 特征相似性 FSIM:

$$S_L(X) = [S_{PC}(X)]^\alpha [S_G(X)]^\beta; \quad (20)$$

$$PC_m(X) = \max(PC_1(X), PC_2(X)); \quad (21)$$

$$FSIM = \frac{\sum_{X \in \Omega} S_L(X) \cdot PC_m(X)}{\sum_{X \in \Omega} PC_m(X)}. \quad (22)$$

3 实验结果与分析

为了验证混沌飞蛾扑火优化算法对膝盖 MRI 图像进行多阈值分割的效果,实验选用 Intel (R) Core (TM) i3-4150 CPU 和 6GB 内存容量的计算机,选择纽约大学和 Facebook AI Research (FAIR) 的 MRI 数据集,并对 Knee (R) 中原始膝盖 MRI 图像进行分割处理.实验过程中采用人群搜索算法 (SOA)^[10]、细菌觅食算法 (BFOA)^[11]、飞蛾扑火算法^[12] (MFO) 3 种算法作实验对比。

3.1 实验结果与对比

从磁共振成像 (MRI) 数据集中任意选取 2 幅原始膝盖 MRI 图像 (如图 2 中图像 a, b 所示),并依次对其分别在 SOA, BFOA, MFO 和本文算法 (CMFO) 4 种算法下进行单、二、三和四阈值分割处理.图 2 为原始膝盖 MRI 图像在 4 种算法下三、四阈值分割结果,不难看出:CMFO 分割的图像更清晰,能更准确地显示原始 MRI 图像的内外结构;同种算法的四阈值分割较三阈值分割处理得到图像局部更加明了,细节更加精确.本实验分别从 PSNR, SSIM 和 FSIM 三种图像质量指标对

图 2 中多阈值分割后的图像进行定量和定性分析.由图 3 中 3 个曲线子图可知,从 PSNR,SSIM 和 FSIM 这 3 种图像质量评价指标的角度分析可

看出:CMFO 较其余 3 种算法具有明显优势,对膝盖 MRI 图像处理能力更强,分割效果更优.




图 2 原始膝盖 MRI 图像与 4 种算法在三、四阈值下的分割结果

Fig. 2 Original knee MRI images and segmentation results of four algorithms under three and four thresholds

(a),(b)—小腿前侧和后侧 MRI 图像;(a1),(b1),(a2),(b2)—SOA 算法;(a3),(b3),(a4),(b4)—BFOA 算法;(a5),(b5),(a6),(b6)—MFO 算法;(a7),(b7),(a8),(b8)—CMFO 算法;(a1,a3,a5,a7),(b1,b3,b5,b7)—三阈值分割结果;(a2,a4,a6,a8),(b2,b4,b6,b8)—四阈值分割结果.




图 3 PSNR (dB), SSIM (dB), FSIM (dB) 折线图

Fig. 3 Polyline diagrams of PSNR (dB), SSIM (dB) and FSIM (dB)

3.2 定量评价与定性分析

由于 MFO 存在收敛速度停滞、易陷入局部最优的缺点,为了证明本文提出的 CMFO 分割算法较标准 MFO 在这两个方面已作了一定的改善,分别从 KSW (适应度函数)最大阈值熵值、运行时间、收敛曲线和标准差 4 个方面进行对比分析,4 种群智能算法均迭代 400 次进行图像分割.

KSW 最大阈值熵的标准差计算公式为

$$\sigma = \sqrt{\frac{1}{k-1} \sum_{i=1}^k (f_i - f)^2}. \quad (23)$$

其中: $k=100$ 为连续运行次数; f_i 和 f_k 分别表示第 i 次 KSW 阈值熵值与第 k 次连续运行后 KSW 熵均值.

表 1 显示了原始膝盖 MRI 图像 2a 和 2b (小

腿前、后侧 MRI 图) 分别在 4 种不同算法处理下先后经单、二、三和四阈值分割处理后得到的图像最大阈值熵值.如表 1 所示,4 种算法对应的单、二阈值分割的 KSW 值几乎完全相同,但三、四阈值分割 KSW 值则彼此间有一定的差值;由于 KSW 值越大对应的图像熵越大,所以针对同种阈值分割,较其他 3 种算法,CMFO 对应的阈值熵最大,所以该方法能够较好地解决 MFO 易陷入局部最优的问题.表 2 显示了原始膝盖 MRI 图像 2a 和 2b 分别在 4 种不同算法处理下先后经单、二、三和四阈值分割处理所需的运行时间.如表 2 所示,针对同种算法,运行时间随着阈值数目的增加也不断增大;针对同一阈值分割,CMFO 算法对应的运行时间在 4 种算法中最短.

表 1 KSW 最大阈值熵值对比
Table 1 Comparison of KSW value

算法	原始膝盖 MRI 图像 2a(小腿前侧图)			
	DIM = 1	DIM = 2	DIM = 3	DIM = 4
SOA	7.948 4	10.849 4	13.523 3	16.081 7
BFOA	7.948 6	10.849 3	13.456 3	15.733 9
MFO	7.948 6	10.849 4	13.469 7	16.184 3
CMFO	7.948 6	10.849 4	13.577 0	16.185 3

算法	原始膝盖 MRI 图像 2b(小腿后侧图)			
	DIM = 1	DIM = 2	DIM = 3	DIM = 4
SOA	7.531 4	10.323 6	13.392 1	15.329 1
BFOA	7.531 3	10.323 6	13.204 0	15.403 9
MFO	7.531 4	10.323 5	13.401 0	15.937 0
CMFO	7.531 4	10.323 6	13.401 1	15.958 6

表 2 运行时间比较
Table 2 Comparison of computing time s

算法	原始膝盖 MRI 图像 2a(小腿前侧图)			
	DIM = 1	DIM = 2	DIM = 3	DIM = 4
SOA	0.363 8	0.388 9	0.428 7	0.447 3
BFOA	0.571 6	0.757 6	0.884 2	0.958 6
MFO	0.157 8	0.198 7	0.218 8	0.233 9
CMFO	0.151 8	0.192 0	0.208 3	0.218 1

算法	原始膝盖 MRI 图像 2b(小腿后侧图)			
	DIM = 1	DIM = 2	DIM = 3	DIM = 4
OA	0.334 7	0.359 2	0.459 8	0.496 9
BFOA	0.467 9	0.726 9	0.805 4	0.875 6
MFO	0.184 4	0.192 3	0.206 7	0.228 3
CMFO	0.163 0	0.179 0	0.201 7	0.220 9

图 4 分析了 4 种算法针对膝盖 MRI 图像分割处理的收敛特性;横坐标 (generation) 代表 4 种算法当前的迭代次数,纵坐标 (fitness) 为 4 种算法当前分割的图像最大阈值熵值.图 4a~4d 表示 4 种算法分别针对数据集中图像 2a 和 2b 进行三、四阈值分割的情况下的迭代收敛曲线.不难看出:CMFO 和 MFO 收敛性比 SOA 和 BFOA 要

好,而且 CMFO 较 MFO 收敛时间更短,寻优速度更快,较好地克服了 MFO 收敛停滞的缺点.表 3 为 4 种算法针对膝盖 MRI 图像 2a 和 2b 的 4 种阈值处理下的 KSW 最大阈值熵值的标准差,可知本文的方法稳定性最好,明显优于 SOA,BFOA 和 MFO 这 3 种算法.




图 4 4 种算法的适应度收敛曲线
Fig. 4 Fitness convergence curves of the four algorithms
(a)—膝盖 MRI 图像 2a DIM = 3; (b)—膝盖 MRI 图像 2b DIM = 3;
(c)—膝盖 MRI 图像 2a DIM = 4; (d)—膝盖 MRI 图像 2b DIM = 4.

表 3 4 种算法的 KSW 最大阈值熵值的标准差
Table 3 Standard deviations of KSW maximum threshold entropy of the four algorithms

算法	原始膝盖 MRI 图像 2a(小腿前侧图)				原始膝盖 MRI 图像 2b(小腿后侧图)			
	DIM = 1	DIM = 2	DIM = 3	DIM = 4	DIM = 1	DIM = 2	DIM = 3	DIM = 4
SOA	2.30E-08	2.848 2E-04	1.308 3E-03	5.658 4E-03	3.56E-08	1.576 9E-05	9.676 1E-04	2.922 9E-03
BFOA	1.27E-08	4.451 6E-03	3.796 0E-03	6.384 6E-03	2.05E-08	1.580 3E-05	5.306 4E-03	4.250 2E-03
MFO	9.79E-09	2.589 1E-04	2.817 3E-03	3.366 5E-03	6.38E-09	3.425 8E-06	2.997 3E-04	2.145 5E-03
CMFO	6.23E-09	2.443 5E-04	2.081 9E-03	2.498 9E-03	3.56E-09	2.297 1E-06	1.769 7E-04	1.160 1E-03

4 结 语

本文在标准 MFO 算法基础上引入了混沌优化策略,提出了一种基于混沌飞蛾扑火(CMFO)的膝盖 MRI 分割算法,旨在同时改善 MFO 优化算法本身仍然存在的收敛停滞,易陷入局部最优的不足. CMFO 算法能够在一定程度上有效地改善标准 MFO 的优化性能,能够帮助飞蛾种群提高其全局搜索能力并及时跳出早熟收敛;本实验中选择膝盖 MRI 图像进行多阈值分割,CMFO 相比于 SOA,BFOA,MFO 能够收敛更快、精度更高地分割,反映出本文提出的基于 CMFO 的膝盖 MRI 图像分割算法在该领域的适用性和优越性.

参考文献:

[1] Morris S A, Slesnick T C. Magnetic resonance imaging [J]. *Visual Guide to Neonatal Cardiology*, 2018, 16 (4) : 104 – 108.

[2] Peric S, Ruzica M, Bojan B, et al. Magnetic resonance imaging of leg muscles in patients with myotonic dystrophies [J]. *Journal of Neurology*, 2017, 264 (9) : 1899 – 1908.

[3] Zaitoun N M, Aqel M J. Survey on image segmentation techniques [J]. *Procedia Computer Science*, 2015, 65 : 797 – 806.

[4] Mavrovouniotis M, Li C, Yang S. A survey of swarm intelligence for dynamic optimization: algorithms and applications [J]. *Swarm and Evolutionary Computation*,

2017, 33 : 1 – 17.

[5] Khairuzzaman A K M, Chaudhury S. Moth-flame optimization algorithm based multilevel thresholding for image segmentation [J]. *International Journal of Applied Metaheuristic Computing*, 2017, 8 (4) : 58 – 83.

[6] Mirjalili S. Moth-flame optimization algorithm: a novel nature-inspired heuristic paradigm [J]. *Knowledge-Based Systems*, 2015, 89 : 228 – 249.

[7] Davis J, Davis L. A hybrid physical and maximum-entropy landslide susceptibility model [J]. *Entropy*, 2015, 17 (6) : 4271 – 4282.

[8] Liu Q, Jiang Z, Shi H. Maximum entropy image segmentation method based on improved firefly algorithm [C] // *Journal of Physics: Conference Series*. Guilin: IOP Publishing Ltd, 2019, 1213 : 032023.

[9] 王坚浩, 张亮, 史超, 等. 基于混沌搜索策略的鲸鱼优化算法 [J]. *控制与决策*, 2018, 33 (7) : 1 – 8.
(Wang Jian-hao, Zhang Liang, Shi Chao, et al. Whale optimization algorithm based on chaotic search strategy [J]. *Control and Decision*, 2018, 33 (7) : 1 – 8.)

[10] Dai C, Chen W, Song Y, et al. Seeker optimization algorithm: a novel stochastic search algorithm for global numerical optimization [J]. *Journal of Systems Engineering and Electronics*, 2010, 21 (2) : 300 – 311.

[11] Kevin M P. Bacterial foraging optimization [J]. *International Journal of Swarm Intelligence Research*, 2010, 1 (1) : 1 – 16.

[12] Muangkote N, Sunat K, Chiewchanwattana S. Multilevel thresholding for satellite image segmentation with moth-flame based optimization [C] // *13th International Joint Conference on Computer Science and Software Engineering*. Khon Kaen: IEEE, 2016 : 1 – 6.

(上接第 325 页)

[2] Luz E, Nunes T M, de Albuquerque V H, et al. ECG arrhythmia classification based on optimum-path forest [J]. *Expert Systems with Applications*, 2013, 40 (9) : 3561 – 3573.

[3] Zhai X, Tin C. Automated ECG classification using dual heartbeat coupling based on convolutional neural network [J]. *IEEE Access*, 2018 (99) : 27465 – 27472.

[4] Xia Y, Gao Z, Zhang H, et al. An automatic cardiac arrhythmia classification system with wearable electrocardiogram [J]. *IEEE Access*, 2018 (6) : 16529 – 16538.

[5] Wu Z, Ding X, Zhang G. A novel method for classification of ECG arrhythmias using deep belief networks [J]. *International Journal of Computational Intelligence and Applications*, 2016, 15 (4) : 1650021.

[6] 庞宇, 邓璐, 林金朝, 等. 基于形态滤波的心电信号去除基线漂移方法 [J]. *物理学报*, 2014, 63 (9) : 428 – 433.
(Pang Yu, Deng Lu, Lin Jin-zhao, et al. A method of

removing baseline drift in ECG signal based on morphological filtering [J]. *Acta Physica Sinica*, 2014, 63 (9) : 428 – 433.)

[7] Martinez J P, Almeida R, Olmos S, et al. A wavelet-based ECG delineator: evaluation on standard databases [J]. *IEEE Transactions on Biomedical Engineering*, 2004, 51 (4) : 570 – 581.

[8] Sajjan M. Learn ECG in a day: a systematic approach [M]. New Delhi: Jaypee Brothers Pvt Ltd, 2013.

[9] Kiranyaz S, Ince T, Gabbouj M, et al. Real-time patient-specific ECG classification by 1D convolutional neural networks [J]. *IEEE Transactions on Biomedical Engineering*, 2015, 63 (3) : 664 – 675.

[10] Jun T J, Nguyen H M, Kang D, et al. ECG arrhythmia classification using a 2-D convolutional neural network [J]. *arXiv Preprint arXiv*, 2018 : 1804. 06812.