

基于改进北方苍鹰优化算法的多阈值图像分割

付雪,朱良宽,黄建平,王璟瑀,ARYSTAN Ryspayev

(东北林业大学 机电工程学院,哈尔滨 150040)

摘要:多阈值图像分割是一种简单、准确、高效且普遍的图像分割方法,相比单阈值图像分割更适用于包含大量信息的彩色图像。在多阈值图像分割中,随着阈值数量的增加,传统的枚举法计算量增大,分割一幅彩色图像不仅需要更多的时间,而且分割精度也随之降低。提出一种基于改进北方苍鹰优化(INGO)算法的多阈值图像分割方法。利用立方混沌优化与透镜成像反向学习策略增加种群多样性,在优化初始解的同时扩大种群搜索范围,使INGO算法尽可能搜索到潜在的最优解,增强算法的搜索能力。将最优最差反向与透镜成像反向学习策略相结合,避免INGO算法易陷入局部最优的情况,提高收敛精度。在对经典的伯克利测试图像进行多阈值彩色图像分割的实验结果表明,在GWO、PSO、ChOA等算法中,INGO算法取得峰值信噪比和特征相似度最优平均值的占比分别为100.000%和78.125%,在保证算法收敛效率的同时获得较优的图像分割结果,在多阈值图像分割领域具有较强的理论应用价值。

关键词:北方苍鹰优化;多阈值分割;对称交叉熵;立方混沌;透镜成像反向学习策略

开放科学(资源服务)标志码(OSID):



源代码链接:<https://github.com/X123g/aaa/tree/main>

中文引用格式:付雪,朱良宽,黄建平,等.基于改进北方苍鹰优化算法的多阈值图像分割[J].计算机工程,2023,49(7):232-241.

英文引用格式:FU X, ZHU L K, HUANG J P, et al. Multi-threshold image segmentation based on improved northern goshawk optimization algorithm[J]. Computer Engineering, 2023, 49(7): 232-241.

Multi-Threshold Image Segmentation Based on Improved Northern Goshawk Optimization Algorithm

FU Xue, ZHU Liangkuan, HUANG Jianping, WANG Jingyu, ARYSTAN Ryspayev

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

[Abstract] Multi-threshold image segmentation is a simple, accurate, efficient, and universal, image segmentation method. Compared with single-threshold image segmentation, it is more suitable for color images containing much information. In multi-threshold image segmentation, the amount of calculation with the traditional enumeration method surges with the increase of threshold number. This takes more time to segment a color image and reduces the precision of segmentation. Therefore, a multi-threshold image segmentation method based on the Improved Northern Goshawk Optimization (INGO) algorithm is proposed. Cubic chaos optimization and lens imaging reverse learning strategy are used to increase population diversity while optimizing initial solutions, which expands the scope of population search, enables the INGO algorithm to better search for potential optimal solutions, and enhances the search ability of the algorithm. A hybrid strategy that combines the optimal worst case inversion with a lens imaging inverse learning strategy can help the INGO algorithm avoid situations where it is prone to fall into a local optimum and improve convergence accuracy. The experimental results of multi-threshold color image segmentation on classic Berkeley test images show that among the algorithms, such as GWO, PSO, and ChOA, the proportion of INGO algorithm achieving the optimal average of Peak Signal-to-Noise Ratio (PSNR) and Feature Similarity Index Measure (FSIM) is 100.000% and 78.125%, respectively. It achieves better image segmentation results while ensuring the convergence efficiency of the algorithm and has strong theoretical application value in the field of multi-threshold image segmentation.

[Key words] Northern Goshawk Optimization (NGO); multi-threshold segmentation; symmetric cross-entropy; cubic chaos; lens imaging reverse learning strategy

DOI:10.19678/j.issn.1000-3428.0065186

基金项目:中央高校基本科研业务费专项资金(DL12EB04-02);国家自然科学基金(31370710);国家林业局948项目(2014-4-26)。

作者简介:付雪(1999—),女,硕士研究生,主研方向为视觉检测、图像处理;朱良宽(通信作者),教授、博士、博士生导师;黄建平,副教授、博士;王璟瑀,博士研究生;ARYSTAN Ryspayev,硕士研究生。

收稿日期:2022-07-08 **修回日期:**2022-08-31 **E-mail:**zhulk@nefu.edu.cn

0 概述

随着计算技术的蓬勃发展,图像采集设备的性能得到大幅提高,彩色图像处理技术受到越来越多研究人员的关注^[1-2]。图像分割是图像处理技术的核心步骤,被广泛应用于图像处理、医学影像、模式识别、机器视觉等相关领域。图像分割技术主要包括边缘检测、阈值分割、区域分割与其他特定理论相结合的传统分割方法以及深度学习方法。深度学习方法近年来广为流行的人工智能技术,广泛应用于计算机视觉领域。深度学习需要依赖神经网络模型选择以及大量分割标签的数据集,对于某些复杂图像需要将其具有特殊含义的部分分割出来作为应用依据。由于深度学习对计算性能要求较高,因此在工程实现方面仍有一定的局限性^[3-4]。基于阈值分割是传统图像分割中简单、准确、高效且普遍的图像分割方法,常见的阈值分割方法有最小交叉熵法^[5]、Otsu法^[6]、最小对称交叉熵法^[7]以及最大熵法^[8]等。在多阈值图像分割中,随着阈值数量的增加,传统枚举法的计算量激增,不仅使得分割一幅彩色图像需要更多的时间,而且分割精度和效果降低。

研究人员利用智能优化算法求解精度较低的问题。例如,WANG等^[9]基于莱维飞行改进樽海鞘算法(Slap Swarm Algorithm, SSA),利用Kapur熵、Otsu和Renyi熵适应度函数对分割结果进行评估,获得了较优的实验结果。吕鑫等^[10]针对传统多阈值图像分割中普遍存在分割精度低、计算量大、分割速度慢等问题,将改进的麻雀搜索算法应用于多阈值分割中,结果表明,基于改进麻雀搜索算法的多阈值分割可以获得最佳的分割阈值,分割精度更高。除此以外,许多经典的群智能优化算法被广泛应用于阈值分割领域^[11-13]。

为了进一步解决彩色图像分割问题,近年来涌现出许多具有较强寻优能力的智能优化算法。北方苍鹰优化(Northern Goshawk Optimization, NGO)算法是由研究人员在2021年提出的一种新颖的群智能优化算法,模拟了北方苍鹰在捕猎过程的行为。虽然北方苍鹰优化算法具有较优的性能,但是仍存在算法收敛精度低、易陷入局部最优等问题^[14]。

本文提出一种改进的北方苍鹰优化(Improved Northern Goshawk Optimization, INGO)算法,在保证运行效率的同时提高图像分割精度。利用立方混沌混合透镜成像反向学习策略初始化北方苍鹰的位置,提高初始解的质量,引入透镜成像与最优最差反向学习的混合反向学习策略,择优选取最优位置,提高算法跳出局部最优的能力。

1 最小对称交叉熵多阈值分割

基于最小对称交叉熵的图像分割方法的关键在于选取分割前后图像信息量差异最小的阈值。其内容为^[15-16]假设有一幅 $M \times N$ 大小的图像,具有 L 个灰度级,灰度范围为 $[0, L-1]$ 。图像中灰度级 l 的所有

像素点的数目记为 h_i ,将一幅彩色图像划分为 $n+1$ 个区域,则需要 $t_1, t_2, \dots, t_n$ 共 n 个阈值进行分割,此时图像的熵表示如式(1)所示:

$$H(t_1, t_2, \dots, t_n) = H_0 + H_1 + \dots + H_n \quad (1)$$

其中:

$$H_0 = \sum_{i=0}^{t_1} h_i \left(i \ln \frac{i}{\mu_0(t)} + \mu_0(t) \ln \frac{\mu_0(t)}{i} \right) \quad (2)$$

$$\mu_0(t) = \sum_{i=0}^{t_1} \frac{iP_i}{\sum_{i=0}^{t_1} P_i}$$

$$H_1 = \sum_{i=t_1+1}^{t_2} h_i \left(i \ln \frac{i}{\mu_1(t)} + \mu_1(t) \ln \frac{\mu_1(t)}{i} \right) \quad (3)$$

$$\mu_1(t) = \sum_{i=t_1+1}^{t_2} \frac{iP_i}{\sum_{i=t_1+1}^{t_2} P_i}$$

$$\vdots$$

$$H_{n-1} = \sum_{i=t_{n-1}+1}^{t_n} h_i \left(i \ln \frac{i}{\mu_{n-1}(t)} + \mu_{n-1}(t) \ln \frac{\mu_{n-1}(t)}{i} \right) \quad (4)$$

$$\mu_{n-1}(t) = \sum_{i=t_{n-1}+1}^{t_n} \frac{iP_i}{\sum_{i=t_{n-1}+1}^{t_n} P_i}$$

本文将图像总熵值最小时的阈值组合表示为 $(t_1^*, t_2^*, \dots, t_n^*)$,则最小对称交叉熵判断如式(5)所示:

$$t(t_1^*, t_2^*, \dots, t_n^*) = \arg \min \{H_0 + H_1 + \dots + H_n\} \quad (5)$$

2 北方苍鹰优化算法

北方苍鹰的狩猎策略可以分为2个阶段:猎物识别阶段(勘探阶段)及追击与逃逸阶段(开发阶段)。NGO根据狩猎阶段不同建立数学模型。

2.1 猎物识别阶段

在北方苍鹰狩猎的第一阶段,北方苍鹰会随机选择一个猎物然后快速攻击它。在此阶段,北方苍鹰行为的数学表达如式(6)~式(8)所示:

$$P_i = X_k, i = 1, 2, \dots, N; k = 1, 2, \dots, i-1, \dots, N \quad (6)$$

$$x_{\text{new}, p_i, i, j} = \begin{cases} x_{i,j} + r(p_{i,j} - Ix_{i,j}), & F_{p_i} < F_i \\ x_{i,j} + r(x_{i,j} - p_{i,j}), & F_{p_i} \geq F_i \end{cases} \quad (7)$$

$$X_i = \begin{cases} x_{\text{new}, p_i, i}, & F_{\text{new}, p_i, i} < F_i \\ X_i, & F_{\text{new}, p_i, i} \geq F_i \end{cases} \quad (8)$$

其中: P_i 为第 i 只北方苍鹰选择猎物的位置; F_{p_i} 为目标函数值,即适应度值; k 为属于 $[1, N]$ 的随机自然数; $x_{\text{new}, p_i, i}$ 为第 i 只北方苍鹰的新状态; $x_{\text{new}, p_i, i, j}$ 为第 i 只北方苍鹰在第 j 维度的新状态; $F_{\text{new}, p_i, i}$ 为与之对应的适应度值; r 为属于 $[0, 1]$ 的随机数; I 的数值为1或者2。 r 和 I 是用于在搜索和更新中生成随机NGO行为的随机数。

2.2 追击与逃逸阶段

在北方苍鹰攻击猎物后,猎物会试图逃跑。因此,在你追我赶的过程中,北方苍鹰的速度极快,它们可以在任何情况下捕获猎物。假设此狩猎处于半

径 R 的攻击位置。第2阶段的数学表达如式(9)~式(11)所示:

$$x_{\text{new},p_2,i,j} = x_{i,j} + R(2r-1)x_{i,j} \quad (9)$$

$$R = 0.02 \left(1 - \frac{t}{T} \right) \quad (10)$$

$$X_i = \begin{cases} X_{\text{new},p_2,i} & F_{\text{new},p_2,i} < F_i \\ X_i & F_{\text{new},p_2,i} \geq F_i \end{cases} \quad (11)$$

其中: t 为当前的迭代次数; T 为最大迭代次数; $X_{\text{new},p_2,i}$ 为在第2个狩猎阶段的第 i 只北方苍鹰的新状态; $x_{\text{new},p_2,i,j}$ 为在第2个狩猎阶段的第 i 只北方苍鹰在第 j 维度的新状态; $F_{\text{new},p_2,i}$ 为新状态下的适应度值。

NGO具有较高的收敛精度和良好的稳定性,但仍存在以下的局限性:1)在种群初始化过程中,初始解的分布是随机且不均匀的,种群中个体质量参差不

齐,很容易导致种群多样性缺失,进而错过潜在的最优解;2)在NGO的第2阶段猎物逃跑过程中,北方苍鹰以极快的速度追逐猎物。基于以上行为特点,NGO算法的后期搜索速度较快,导致算法陷入局部最优。

3 北方苍鹰优化算法的改进

3.1 立方混沌初始化

混沌描述了一种在无规律变化表象下的不确定规则变动原理^[17]。在标准NGO算法中,北方苍鹰的初始位置是随机分布的,位置分布不均匀。因此,在标准NGO算法中,引入混沌序列初始化种群,提高种群中解的质量。目前常用的混沌优化方法有Logistic映射^[18-19]、Singer映射^[20]、Sine映射^[21]、Cubic映射^[22-23]等。混沌分布示意图如图1所示。




图1 混沌分布示意图

Fig.1 Schematic diagram of chaos distribution

本文选择分布更均匀的Cubic映射(立方混沌映射)生成混沌序列,从而获得分布更加均匀的种群。Cubic映射定义如式(12)所示:

$$x_{n+1} = \rho x_n (1 - x_n^2) \quad (12)$$

其中: $x_n \in (0, 1)$; ρ 为控制参数,本文中 $\rho = 2.595$ 。

3.2 最优最差反向学习策略

最优最差反向学习策略是针对算法中的最优个体与最差个体进行优化,其主要目的是在保证当前最优个体跳出局部最优的同时,平衡算法的全局搜索能力与局部搜索能力^[24]。

利用最优反向学习对最优北方苍鹰个体位置进行优化,以提高NGO算法的局部探索能力,避免NGO算法早熟收敛。最优个体反向学习如式(13)所示:

$$X_{\text{best}}^*(i) = l_b + (u_b - X_{\text{best}}(i)) \quad (13)$$

其中: l_b 和 u_b 为当前最优个体的下限与上限; $X_{\text{best}}(i)$

为当前最优北方苍鹰位置向量; $X_{\text{best}}^*(i)$ 为与之对应的反向位置向量。

通过对最差北方苍鹰个体位置进行随机反向学习策略,达到提高NGO算法全局搜索能力的目的。具体数学表达如式(14)所示:

$$X_{\text{worst}}^*(i) = l'_b + \text{rand}(u'_b - X_{\text{worst}}(i)) \quad (14)$$

其中: l'_b 和 u'_b 为当前最差个体的下限与上限; rand 为随机向量; $X_{\text{worst}}(i)$ 为当前最差北方苍鹰位置向量; $X_{\text{worst}}^*(i)$ 为与之对应的反向位置向量。

3.3 透镜成像反向学习策略

透镜成像反向学习策略是基于光的透镜成像原理(折射原理)的反向学习策略。基于透镜成像的反向学习策略根据缩放因子动态调节反向解的数量,从而优化种群数量并使NGO算法避免陷入局部最优^[25]。透镜成像原理如图2所示。




图 2 透镜成像原理示意图

Fig.2 Schematic diagram of lens imaging principle

凸透镜的成像规律如式(15)所示:

$$\frac{1}{u} + \frac{1}{v} = \frac{1}{f} \tag{15}$$

其中: u 、 v 、 f 分别表示物距、像距与焦距。图 2 中 O 为基点, a_d 与 b_d 为可行解的区间范围, $A'B'$ 为 AB 经过凸透镜折射形成的影像, 高度分别为 h 与 h' 。假定 AB 的坐标位置为 X_i , $A'B'$ 的坐标位置 X_i^* (反向点)。透镜成像原理表示如式(16)所示:

$$\frac{(a_d + b_d)}{2} - X_i = \frac{h}{h'} \tag{16}$$
$$X_i^* = \frac{(a_d + b_d)}{2}$$

令 $m = \frac{h}{h'}$ 表示缩放因子, 则 X_i^* 的表达如式(17)所示:

$$X_i^* = \frac{(a_d + b_d)}{2} + \frac{(a_d + b_d)}{2m} - \frac{X_i}{m} \tag{17}$$

其中: a_d 与 b_d 为固定值。在当前解与反向解之间的距离由缩放因子 m 决定, 随着 m 值的增大, 反向解的范围越接近当前解。特别地, 当 $m = 1$ 时, 式(17)为一般的反向学习策略。

3.4 算法描述

针对种群分布不均匀问题, 本文基于 NGO 算法, 引入立方混沌与反向折射机制相结合的方法丰富种群的多样性。INGO 的流程如图 3 所示。针对 NGO 算法早熟收敛情况, 本文采用小孔成像反向学习策略与最差反向学习策略相结合的混合反向学习策略改进标准 NGO 算法, 在提高 NGO 全局搜索能力的同时帮助算法逃逸局部最优。




图 3 改进北方苍鹰优化算法流程

Fig.3 Procedure of improved northern goshawk optimization algorithm

4 彩色图像分割实验

4.1 实验背景

本文实验选取来自伯克利大学的图像分割数据集 BSDS500 的 8 幅实验图像(人像 2 幅,动物图像 3 幅,建筑物 3 幅)进行分割实验,并选择粒子群优化(Particle Swarm Optimization, PSO)算法^[11]、灰狼优化(Grey Wolf Optimization, GWO)算法^[12]、黑猩猩优化算法(Chimp Optimization Algorithm, ChOA)^[13]、海鸥优化算法(Seagull Optimization Algorithm, SOA)^[26]、FSA 与 INGO 进行对比分析。通过峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)与特征相似度(Feature Similarity Index Measure, FSIM)的平均值、标准差、最优阈值与算法效率评估实验结果。

PSNR 通常用来评价一幅图像压缩前后失真情况^[27-29]。均方误差(Mean Square Error, MSE)和 PSNR 的计算过程如式(18)和式(19)所示:

$$M_{\text{MSE}} = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} \|I(i,j) - K(i,j)\|^2 \quad (18)$$

$$P_{\text{PSNR}} = 10 \log_a \left(\frac{M_{\text{MAX},i}^2}{M_{\text{MSE}}} \right) = 20 \log_a \left(\frac{M_{\text{MAX},i}}{\sqrt{M_{\text{MSE}}}} \right) \quad (19)$$

其中:MAX 表示图像的最大灰度值。

FSIM 是基于低层视觉特性相似的特征相似度评价方法^[28-29],计算过程如式(20)所示:

$$F_{\text{FSIM}} = \frac{\sum_{x \in \Omega} \left[\frac{2P_{\text{PC},1}(x)P_{\text{PC},2}(x) + T_1}{P_{\text{PC},1}^2 + P_{\text{PC},2}^2 + T_1} \right]^\alpha \left[\frac{2C_1(x)C_2(x) + T}{C_1(x)^2 + C_2(x)^2 + T_2} \right]^\beta P_{\text{PC},m}(x)}{\sum_{x \in \Omega} P_{\text{PC},m}(x)} \quad (20)$$

其中: $P_{\text{PC},m}(x) = \max(P_{\text{PC},1}(x), P_{\text{PC},2}(x))$; $\alpha = 1$; $\beta = 1$ 。

4.2 实验设计

图像分割阈值设定为 4、6、8 和 10。本文实验迭代次数 100,所选取得到伯克利测试图片的原图与直方图如图 4 所示。本文实验在 2.20 GHz CPU 和 12 GB 内存的 PC 机、Windows10 的操作系统以及 Matlab R2019a 环境中进行。所有算法的种群大小取值均为 30。实验数据选用各算法独立运行 20 次的平均结果。优化算法的特有参数取值如表 1 所示。




图 4 测试图像及直方图

Fig.4 Test images and histograms

表 1 不同算法的参数取值
Table 1 Parameter values among different algorithms

算法	参数值
INGO	$n=1.02 \times 10^{-4}$
PSO	$\omega=0.95, c_1=c_2=2, v_{\max}=6$
GWO	$a \in [0.2], r_1 \in [0, 1], r_2 \in [0, 1]$
ChOA	$f \in [0, 2]$
SOA	$f_c=4, u=1, v=1$

5 实验结果与分析

5.1 图像评价指标

表 2 所示为不同算法对伯克利测试图像分割后

的 FSIM 与 PSNR 的平均值,加粗表示最优数据。从表 2 可以看出:随着阈值 K 逐渐递增,各算法分割后图像的 FSIM、PSNR 值呈上升趋势,图像分割前后的峰值信噪比、结构相似度逐渐增大。INGO 的 FSIM 和 PSNR 指标取得最优平均值分别占比 78.125% 和 100%,说明基于 INGO 分割后的图像 FSIM、PSNR 指标相比其他算法表现出更明显的优势,尤其表现在 INGO 分割前后图像的失真程度最低,保证了分割前后 2 张图像的相似度。随着阈值的增加,INGO 的 FSIM、PSNR 值与其他算法间的差异越来越明显,说明利用 INGO 求解最优阈值后得到的分割图像与原始图像最接近,保留了原始图像更多的信息,体现了 INGO 算法优异的全局搜索能力。

表 2 不同算法的 FSIM、PSNR 平均值对比
Table 2 Comparison of average values of FSIM, PSNR among different algorithms

图像	K	FSIM						PSNR/dB					
		INGO	GWO	PSO	ChOA	FSA	SOA	INGO	GWO	PSO	ChOA	FSA	SOA
图像 1	4	0.786 2	0.786 0	0.788 0	0.790 9	0.785 0	0.780 4	18.017 9	17.989 3	17.987 7	16.081 3	17.798 1	17.116 7
	6	0.845 8	0.846 0	0.850 7	0.833 3	0.845 1	0.827 2	21.340 9	21.089 3	20.616 2	20.075 1	20.102 2	18.735 2
	8	0.886 0	0.880 6	0.883 1	0.876 6	0.877 8	0.880 2	24.040 8	23.744 8	22.992 5	22.162 1	22.261 9	21.626 8
	10	0.928 4	0.914 9	0.845 1	0.892 8	0.904 3	0.890 4	25.938 3	25.172 4	24.607 6	23.398 3	24.027 1	22.550 4
图像 2	4	0.824 8	0.808 9	0.811 7	0.830 1	0.823 4	0.818 6	19.378 3	19.221 3	19.117 6	18.824 3	18.736 2	17.587 5
	6	0.879 3	0.877 4	0.871 7	0.869 3	0.871 1	0.848 2	22.086 8	21.684 6	21.088 0	20.764 6	20.742 9	19.938 8
	8	0.904 1	0.896 7	0.905 6	0.888 0	0.899 3	0.875 2	24.582 0	23.631 6	23.073 8	22.638 8	23.415 1	21.264 4
	10	0.929 7	0.921 6	0.920 1	0.914 6	0.917 9	0.895 9	25.944 7	25.065 1	24.929 2	23.720 2	24.605 3	22.534 1
图像 3	4	0.862 5	0.861 9	0.866 1	0.870 2	0.870 5	0.866 4	18.398 5	18.358 4	18.292 5	18.086 8	18.229 1	17.365 3
	6	0.919 8	0.916 2	0.913 9	0.902 9	0.914 9	0.898 7	21.574 8	21.448 0	21.127 9	20.470 9	20.985 2	19.854 8
	8	0.938 0	0.935 9	0.934 2	0.928 6	0.929 0	0.918 0	23.591 5	23.277 4	22.959 7	22.498 2	22.576 2	21.015 1
	10	0.950 3	0.946 5	0.941 6	0.935 7	0.941 1	0.926 8	25.181 0	24.634 6	24.197 2	23.650 9	23.977 6	22.537 6
图像 4	4	0.872 6	0.872 2	0.871 2	0.871 5	0.875 2	0.890 1	18.289 4	18.077 7	18.041 7	17.921 0	18.152 8	17.027 3
	6	0.904 6	0.901 9	0.901 8	0.900 4	0.901 4	0.892 0	20.375 8	19.969 2	19.538 0	19.898 5	19.826 9	18.477 2
	8	0.923 5	0.918 2	0.921 9	0.913 2	0.917 5	0.910 8	23.684 0	22.514 8	21.439 8	21.864 7	21.849 1	20.630 0
	10	0.939 3	0.930 6	0.931 4	0.926 3	0.931 3	0.922 7	25.713 2	24.511 2	23.970 4	23.723 9	23.388 3	22.300 0
图像 5	4	0.852 7	0.850 7	0.852 8	0.840 7	0.852 3	0.841 2	18.249 6	18.188 8	18.131 7	17.347 6	18.082 8	16.916 9
	6	0.908 2	0.903 3	0.899 9	0.884 7	0.897 7	0.887 5	21.035 4	20.793 3	20.486 7	19.494 5	20.413 8	18.954 9
	8	0.931 5	0.926 9	0.924 4	0.916 0	0.922 6	0.918 5	23.091 5	22.731 2	22.451 8	21.435 6	22.367 6	20.893 6
	10	0.946 1	0.939 1	0.936 8	0.931 4	0.933 4	0.930 9	24.812 4	24.197 9	23.710 3	22.945 4	21.397 3	22.268 8
图像 6	4	0.820 2	0.819 6	0.818 9	0.819 8	0.819 8	0.812 4	17.277 4	17.200 4	17.066 0	16.664 2	16.934 0	15.716 5
	6	0.858 8	0.857 3	0.855 3	0.845 6	0.856 8	0.842 1	20.548 4	20.152 3	19.988 1	18.449 1	19.771 8	18.652 6
	8	0.892 8	0.887 1	0.882 1	0.864 3	0.873 0	0.863 4	22.720 3	21.758 5	21.769 9	20.879 4	21.060 9	20.007 5
	10	0.910 1	0.899 2	0.899 8	0.889 1	0.899 4	0.869 0	24.285 5	23.229 8	23.533 2	22.656 2	23.468 3	21.580 2
图像 7	4	0.880 1	0.879 8	0.878 6	0.875 8	0.878 7	0.865 4	16.698 0	16.596 6	16.593 0	16.669 0	16.459 9	16.358 4
	6	0.932 6	0.929 2	0.928 4	0.920 5	0.925 7	0.902 3	19.484 4	18.972 6	19.160 6	18.936 8	18.936 4	18.123 0
	8	0.956 3	0.951 6	0.944 4	0.932 8	0.941 9	0.920 9	21.053 3	20.605 3	20.452 3	20.202 4	19.587 3	20.148 9
	10	0.965 8	0.961 9	0.949 1	0.945 3	0.956 1	0.936 9	22.325 6	21.611 7	21.733 6	21.669 6	21.367 6	21.360 5
图像 8	4	0.868 6	0.868 5	0.868 2	0.871 5	0.869 5	0.847 6	18.237 1	18.151 7	18.176 4	17.898 7	18.136 5	16.999 9
	6	0.921 2	0.917 1	0.919 4	0.914 1	0.917 2	0.892 7	20.921 1	20.655 8	20.693 7	20.070 5	20.404 3	19.171 0
	8	0.945 8	0.942 8	0.938 1	0.934 3	0.933 3	0.922 0	22.815 6	22.470 1	22.245 7	21.662 1	19.942 2	20.864 3
	10	0.957 5	0.953 9	0.948 4	0.941 4	0.947 8	0.932 7	24.121 7	23.719 0	23.445 3	22.893 4	23.167 0	21.707 2

不同算法分割伯克利测试图像的FSIM、PSNR标准差如图5和图6所示。从图5和图6可以看出：在绝大多数情况下INGO的FSIM、PSNR指标的标准差都处于折线图最底端，说明INGO算法在图像

分割实验中得到的各项指标值能够稳定在一个固定区间内，运行稳定性优于GWO、PSO等算法。INGO算法得到FSIM、PSNR指标标准差最小的情况分别占比78.125%和93.75%。




图5 不同算法的FSIM指标对比

Fig.5 FSIM indicators comparison among different algorithms




图6 不同算法的PSNR指标对比

Fig.6 PSNR indicators comparison among different algorithms

因此，本文通过对各算法的图像评价指标数据加以分析后可以得出：虽然INGO算法在阈值个数

较少时与GWO等对比算法的FSIM和PSNR均值差异较小，但是随着阈值数的增加，INGO获得分割后

图像质量最高的情况最多,运行稳定性最优。

5.2 最优适应度值

表 3 所示为不同算法对各图像的最优适应度值对比。适应度值的大小表示图像的对称交叉熵总和,最优适应度值越小,获得的阈值越佳,图像分割质量越

高。例如,当阈值 K 为 8 时,INGO、GWO、PSO、ChOA、FSA 和 SOA 算法对图像 1 的最优适应度值分别为 85 000.41、85 571.10、104 457.12、120 103.58、98 263.47、151 502.71。INGO 算法获得的最优适应度值最小,与之对应的 FSIM、PSNR 均值最高。

表 3 不同算法的最优适应度值对比
Table 3 Optimal fitness values comparison among different algorithms

图像	K	最优适应度值					
		INGO	GWO	PSO	ChOA	FSA	SOA
图像 1	4	223 212.12	223 212.12	223 936.66	235 276.93	227 382.31	278 204.24
	6	130 498.36	131 428.37	142 222.66	150 332.63	153 117.78	208 341.84
	8	85 000.41	85 571.10	104 457.12	120 103.58	98 263.47	151 502.71
	10	61 637.93	66 932.61	83 745.73	100 609.14	87 417.12	102 167.74
图像 2	4	168 325.78	168 418.29	169 532.23	186 404.28	198 339.52	214 241.61
	6	87 066.66	91 710.46	95 381.04	109 392.09	112 644.59	168 515.09
	8	60 391.26	61 394.84	70 305.54	83 165.22	71 843.13	112 973.92
	10	43 671.34	45 996.44	56 485.74	65 459.48	50 195.97	92 395.52
图像 3	4	221 243.45	221 354.07	221 882.20	200 463.41	232 788.65	294 975.50
	6	119 979.04	121 471.51	127 170.98	236 228.71	145 157.89	212 533.63
	8	75 612.71	81 024.62	87 989.04	93 370.56	76 536.97	137 502.46
	10	52 669.02	56 328.83	67 502.02	90 761.09	69 671.00	112 375.44
图像 4	4	157 515.23	158 453.81	157 855.80	176 792.67	159 835.15	210 361.18
	6	81 124.41	81 267.22	66 567.39	100 690.33	71 237.72	149 309.17
	8	54 497.31	56 466.56	61 857.75	78 005.51	52 415.82	103 036.16
	10	41 623.64	43 202.26	47 073.62	55 810.69	51 074.22	76 795.22
图像 5	4	165 348.50	165 410.06	166 727.95	200 463.41	159 817.13	271 046.80
	6	89 192.18	92 464.73	96 287.02	126 607.13	89 056.62	134 806.53
	8	57 105.71	63 928.15	65 360.51	82 604.33	69 887.94	127 123.92
	10	40 087.81	44 496.68	51 202.74	67 404.04	51 834.40	87 585.23
图像 6	4	100 703.39	101 318.10	101 300.89	127 807.07	114 583.53	140 815.20
	6	55 330.01	55 503.16	66 567.39	79 893.32	72 526.43	103 462.59
	8	38 018.17	42 577.16	43 831.17	59 013.45	52 415.82	80 681.21
	10	28 245.08	31 713.51	32 969.50	44 569.45	30 547.64	55 456.48
图像 7	4	286 584.02	286 744.73	287 762.63	299 054.79	294 942.51	303 361.01
	6	140 991.18	141 432.54	142 543.16	174 006.34	175 980.83	184 593.20
	8	83 791.86	84 230.93	89 588.26	108 594.76	111 267.36	167 741.54
	10	57 422.67	57 736.57	74 823.76	75 407.91	76 782.86	80 850.58
图像 8	4	200 766.14	202 396.53	201 299.46	218 762.43	209 953.37	344 851.35
	6	103 749.26	117 955.97	107 797.09	144 593.99	117 996.27	191 640.47
	8	67 482.48	72 583.15	82 033.26	95 251.04	91 064.48	115 592.40
	10	45 561.63	47 413.93	54 874.55	72 971.99	58 710.89	106 513.61

从表 3 可以看出:INGO 算法在本文进行的大部分实验中均获得最小的最优适应度值,当选取的阈值较小时,INGO 与其他算法的适应度差值并不大,但是随着阈值的增加,这种差值随之增加。这一趋势表明 INGO 算法可以增强算法的局部搜索能力,避免算法陷入局部最优,从而提高算法的求解精度。

5.3 算法效率

为进一步直观地展示 INGO 的寻优性能,本文

给出各算法对图像 1 进行分割的适应度收敛曲线,结果如图 7 所示(彩色效果见《计算机工程》官网 HTML 版)。INGO 算法的收敛精度高于经典智能优化算法 GWO、PSO 与新兴优化算法 ChOA、FSA,并且随着选择阈值的增加,INGO 与其他 4 种对比算法之间的收敛精度差距随之增加。从图 7 可以看出:在相同迭代次数条件下,INGO 的收敛速度明显优于 GWO、PSO、ChOA 与 FSA 算法。特别地,在

INGO的收敛曲线处均有多处转折点,反映了INGO能够有效避免局部最优情况。因此,INGO不仅可

以提高图像的分割精度,而且算法的效率也位居前茅。




图7 不同算法对图像1分割的适应度收敛曲线

Fig.7 Adaptability convergence curves among different algorithms for image 1 segmentation

综上所述,从图像评价指标、最优适应度值与算法效率3个方面对6种优化算法的性能进行分析,在绝大多数的情况下,本文提出的INGO算法都可以获得最优阈值并使分割前后的图像差异更小。因此,INGO算法在彩色图像分割中具有有效性与实用性,广泛应用于各种复杂图像处理。

6 结束语

针对传统多阈值分割方法计算复杂度高的问题,本文提出一种基于改进北方苍鹰优化(INGO)的彩色图像分割方法。引入立方混沌、最优最差反向学习与透镜成像反向学习策略,通过对北方苍鹰优化算法进行改进,以图像的对称交叉熵总和作为适应度值函数,利用北方苍鹰种群的狩猎行为快速且精确地搜索图像的最优分割阈值。实验结果表明,相比GWO、PSO等算法,基于INGO算法获得的分割图像质量更优,算法运行更稳定。下一步将利用INGO与不同的信息熵方法相结合,对彩色图像进行应用扩展研究,如复杂的遥感图像和医学图像分割问题。此外,将INGO用于工程结构设计等复杂的优化问题也是本文研究的重点方向。

参考文献

- [1] SKARBEBEK W, KOSCHAN A. Colour image segmentation-a survey[EB/OL]. [2022-06-03]. <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.28.1325&rep=rep1&type=pdf>.
- [2] 朱良宽,刘亮,东旭,等. 基于改进三维Otsu法的森林冠层图像分割[J]. 计算机工程,2019,45(1):253-258,263. ZHU L K, LIU L, DONG X, et al. Forest canopy image segmentation based on improved 3D Otsu method[J]. Computer Engineering, 2019, 45(1): 253-258, 263. (in Chinese)
- [3] RAMESH K K D, KUMAR G K, SWAPNA K, et al. A review of medical image segmentation algorithms[J]. EAI Endorsed Transactions on Pervasive Health and Technology, 2021, 7(27):169184.
- [4] 张相芬,刘艳,袁非牛. 基于倒金字塔深度学习网络的三维医学图像分割[J]. 计算机工程,2022,48(12):304-311. ZHANG X F, LIU Y, YUAN F N. 3D medical image segmentation based on inverted pyramid deep learning network[J]. Computer Engineering, 2022, 48(12):304-311. (in Chinese)
- [5] LI C H, LEE C K. Minimum cross entropy thresholding[J]. Pattern Recognition, 1993, 26(4):617-625.
- [6] OTSU N. A threshold selection method from gray-level histograms[J]. IEEE Transactions on Systems, Man, and Cybernetics, 1979, 9(1):62-66.

- [7] HAN B, WU Y Q. A novel active contour model based on modified symmetric cross entropy for remote sensing river image segmentation[J]. *Pattern Recognition*, 2017, 67: 396-409.
- [8] TURAJLIC E, BUZA E, AKAGIC A. Multilevel image thresholding based on Rao algorithms and Kapur's entropy[C]//*Proceedings of International Conference on Information, Communication and Automation Technologies*. Washington D. C., USA: IEEE Press, 2022: 1-7.
- [9] WANG S K, JIA H M, PENG X X. Modified salp swarm algorithm based multilevel thresholding for color image segmentation[J]. *Mathematical Biosciences and Engineering*, 2020, 17(1): 700-724.
- [10] 吕鑫,慕晓冬,张钧,等. 混沌麻雀搜索优化算法[J]. *北京航空航天大学学报*, 2021, 47(8): 1712-1720.
- LU X, MU X D, ZHANG J, et al. Chaos sparrow search optimization algorithm[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2021, 47(8): 1712-1720. (in Chinese)
- [11] KENNEDY J, EBERHART R. Particle swarm optimization[C]//*Proceedings of International Conference on Neural Networks*. Washington D. C., USA: IEEE Press, 2002: 1942-1948.
- [12] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. *Advances in Engineering Software*, 2014, 69: 46-61.
- [13] KHISHE M, MOSAVI M R. Chimp optimization algorithm[J]. *Expert Systems With Applications*, 2020, 149: 113338.
- [14] DEGHANI M, HUBÁLOVSKÝ Š, TROJOVSKÝ P. Northern goshawk optimization: a new swarm-based algorithm for solving optimization problems[J]. *IEEE Access*, 2021, 9: 162059-162080.
- [15] KULLBACK S, LEIBLER R A. On information and sufficiency[J]. *The Annals of Mathematical Statistics*, 1951, 22(1): 79-86.
- [16] 吴一全,张晓杰,吴诗姘. 2维对称交叉熵图像阈值分割[J]. *中国图象图形学报*, 2011, 16(8): 1393-1401.
- WU Y Q, ZHANG X J, WU S H. Two-dimensional symmetric cross-entropy image thresholding[J]. *Journal of Image and Graphics*, 2011, 16(8): 1393-1401. (in Chinese)
- [17] 李兵,蒋慰孙. 混沌优化方法及其应用[J]. *控制理论与应用*, 1997, 14(4): 613-615.
- LI B, JIANG W S. Chaos optimization method and its application[J]. *Control Theory & Applications*, 1997, 14(4): 613-615. (in Chinese)
- [18] ALATAS B, AKIN E, OZER A B. Chaos embedded particle swarm optimization algorithms[J]. *Chaos, Solitons and Fractals*, 2007, 40(4): 1715-1734.
- [19] 王改云,陆家卓,焦傲,等. 混沌粒子群鸡群融合优化的 RSSI 质心定位算法[J]. *计算机工程*, 2021, 47(6): 197-202, 209.
- WANG G Y, LU J Z, JIAO A, et al. RSSI centroid location algorithm optimized by chaotic particle swarm and chicken swarm[J]. *Computer Engineering*, 2021, 47(6): 197-202, 209. (in Chinese)
- [20] VAROL ALTAY E, ALATAS B. Bird swarm algorithms with chaotic mapping[J]. *Artificial Intelligence Review*, 2020, 53(2): 1373-1414.
- [21] JIN J L, XING L Y, SHEN J Q, et al. Design of a dynamic sparse circulant measurement matrix based on a new compound sine chaotic map[J]. *IEEE Access*, 2022, 10: 10827-10837.
- [22] 张孟健,张浩,陈曦,等. 基于 Cubic 映射的灰狼优化算法及应用[J]. *计算机工程与科学*, 2021, 43(11): 2035-2042.
- ZHANG M J, ZHANG H, CHEN X, et al. A grey wolf optimization algorithm based on Cubic mapping and its application[J]. *Computer Engineering & Science*, 2021, 43(11): 2035-2042. (in Chinese)
- [23] FENG J H, ZHANG J, ZHU X S, et al. A novel chaos optimization algorithm[J]. *Multimedia Tools and Applications*, 2017, 76(16): 17405-17436.
- [24] 耿召里,李目,曹淑睿,等. 基于混合反向学习策略的鲸鱼优化算法[J]. *计算机工程与科学*, 2022, 44(2): 355-363.
- GENG Z L, LI M, CAO S R, et al. A whale optimization algorithm based on hybrid reverse learning strategy[J]. *Computer Engineering & Science*, 2022, 44(2): 355-363. (in Chinese)
- [25] 龙文,伍铁斌,唐明珠,等. 基于透镜成像学习策略的灰狼优化算法[J]. *自动化学报*, 2020, 46(10): 2148-2164.
- LONG W, WU T B, TANG M Z, et al. Grey wolf optimizer algorithm based on lens imaging learning strategy[J]. *Acta Automatica Sinica*, 2020, 46(10): 2148-2164. (in Chinese)
- [26] DHIMAN G, KUMAR V. Seagull optimization algorithm: theory and its applications for large-scale industrial engineering problems[J]. *Knowledge-Based Systems*, 2018, 165: 169-196.
- [27] OLIVA D, CUEVAS E, PAJARES G, et al. Multilevel thresholding segmentation based on harmony search optimization[EB/OL]. [2022-06-03]. <https://downloads.hindawi.com/journals/jam/2013/575414.pdf>.
- [28] ZHANG L, ZHANG L, MOU X Q, et al. FSIM: a feature similarity index for image quality assessment[EB/OL]. [2022-06-03]. <https://citeseerx.ist.psu.edu/viewdoc/download;jsessionid=04EF80B11E9F5E27DB9F4EF483D34179?doi=10.1.1.297.8459&rep=rep1&type=pdf>.
- [29] HOUSSEIN ESSAM H, EL-DIN H B, DIEGO O, et al. An efficient multi-thresholding based COVID-19 CT images segmentation approach using an improved equilibrium optimizer[J]. *Biomedical Signal Processing and Control*, 2022, 73: 103404.