

基于分布反馈螺旋扰动连续蚁群算法的多阈值图像分割研究

赵仕豪

温州大学计算机与人工智能学院, 浙江 温州

收稿日期: 2026年5月18日; 录用日期: 2026年6月22日; 发布日期: 2026年6月30日

摘要

多阈值图像分割是图像处理领域中的重要研究内容, 其核心在于根据图像灰度分布自动确定一组最优阈值, 从而实现图像区域的有效划分。随着阈值数量的增加, 候选阈值组合的搜索空间迅速扩大, 传统穷举方法计算代价较高, 而普通群智能优化算法又容易出现收敛速度慢、寻优精度不足以及陷入局部最优等问题。针对上述问题, 本文提出一种基于分布反馈螺旋扰动的改进连续蚁群优化算法(DFSACO), 并将其应用于多阈值图像分割任务。该方法首先利用连续蚁群优化算法构建阈值搜索模型, 通过解档案保存优质阈值组合, 并采用高斯核采样方式生成候选解; 随后设计分布反馈螺旋扰动算子, 根据当前解档案的分布中心、最优解位置以及档案离散程度, 对候选解进行自适应扰动更新, 从而在保持算法局部开发能力的同时增强全局搜索能力。最后, 采用Kapur熵作为图像分割目标函数, 对多阈值组合进行优化求解。本文方法能够有效提升连续蚁群优化算法在复杂阈值空间中的搜索能力, 为群智能优化算法在图像分割中的应用提供了一种新的思路。

关键词

多阈值图像分割, 连续蚁群优化, Kapur熵, 群智能优化

Research on Multilevel Threshold Image Segmentation Based on Distribution-Feedback Spiral Perturbation Continuous Ant Colony Optimization

Shihao Zhao

College of Computer Science and Artificial Intelligence, Wenzhou University, Wenzhou Zhejiang

Received: May 18, 2026; accepted: June 22, 2026; published: June 30, 2026

Abstract

Multilevel threshold image segmentation is an important topic in image processing, and its key objective is to automatically determine a set of optimal thresholds according to the gray-level distribution of an image. As the number of thresholds increases, the search space of candidate threshold combinations expands rapidly. Traditional exhaustive methods usually suffer from high computational cost, while common swarm intelligence algorithms may face slow convergence, insufficient optimization accuracy, and premature convergence. To address these issues, this paper proposes an improved continuous ant colony optimization algorithm based on a distribution-feedback spiral perturbation strategy and applies it to multilevel threshold image segmentation (DFSACO). The proposed method first constructs a threshold search model using continuous ant colony optimization, where an archive is employed to store high-quality threshold combinations and Gaussian kernel sampling is used to generate candidate solutions. Then, a distribution-feedback spiral perturbation operator is designed to adaptively update candidate solutions according to the distribution center, the current best solution, and the dispersion degree of the archive. In this way, the algorithm can enhance global exploration while maintaining local exploitation. Finally, Kapur's entropy is adopted as the objective function to optimize the multilevel threshold combination. The proposed method improves the search capability of continuous ant colony optimization in complex threshold spaces and provides a feasible approach for applying swarm intelligence algorithms to image segmentation.

Keywords

Multilevel Threshold Image Segmentation, Continuous Ant Colony Optimization, Kapur's Entropy, Swarm Intelligence Optimization

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

图像分割是图像处理、计算机视觉和模式识别等领域中的基础任务，其目标是根据图像的灰度、颜色、纹理或空间结构等特征，将图像划分为若干具有一致属性的区域。图像分割结果的质量会直接影响后续目标检测、图像识别、医学诊断、遥感分析以及工业视觉检测等任务的性能。因此，如何设计一种简单、高效且稳定的图像分割方法，一直是图像处理领域的重要研究方向。

在众多图像分割方法中，阈值分割因其原理简单、计算效率高、易于实现等优点，被广泛应用于灰度图像分割任务。传统单阈值分割方法通过一个阈值将图像划分为目标和背景两个区域，但在实际图像中，不同目标或不同区域往往具有多种灰度分布特征，仅依靠单一阈值难以获得理想的分割效果。因此，多阈值图像分割方法得到了广泛关注。该方法通过多个阈值将图像划分为多个区域，能够更好地适应复杂图像中的多区域结构。

多阈值图像分割的关键在于如何确定最优阈值组合。常见的阈值评价准则包括 Otsu 类间方差法[1]、Kapur 熵法[2]以及最小交叉熵法[3]等。其中，Kapur 熵法通过最大化各分割区域的信息熵来确定最优阈值，能够较好地反映图像灰度分布中的信息结构，因而在多阈值图像分割中具有较好的适用性。然而，随着阈值数量的增加，候选阈值组合数量呈指数级增长，传统穷举搜索方法会带来较大的计算开销，难

以满足实际应用中计算效率的需求。

为解决多阈值分割中的复杂优化问题,研究者逐渐将粒子群优化、遗传算法、灰狼优化、鲸鱼优化、蚁群优化等群智能优化算法引入阈值搜索过程。这类算法不依赖目标函数的梯度信息,能够通过种群协同搜索在较大范围内寻找较优阈值组合,从而有效降低多阈值分割问题的求解复杂度。然而,随着阈值数量增加,搜索空间呈指数级扩展,普通群智能优化算法仍可能面临收敛速度下降、种群多样性不足以及局部最优等问题。因此,如何在保持全局搜索能力的同时增强局部开发能力,是多阈值分割优化中的关键问题。其中,连续蚁群优化算法是一种适用于连续优化问题的蚁群优化方法。该算法通过构建解档案保存优质解,并基于概率模型和高斯采样机制生成新解,能够在连续阈值空间中实现较稳定的搜索,具有较好的通用性和可扩展性。

然而,原始连续蚁群优化算法在处理复杂多阈值图像分割任务时仍存在一定不足。一方面,算法主要依赖档案中的优质解进行高斯采样,当解档案逐渐集中时,种群多样性容易下降;另一方面,在阈值数量较多时,搜索空间复杂度增加,算法可能在局部区域内过早收敛,导致最终分割结果不稳定。针对这些问题,本文提出一种基于分布反馈螺旋扰动的改进连续蚁群优化算法。该方法在标准 ACOR 采样的基础上,引入分布中心、当前最优解和档案离散度等信息,对新生成解进行二次扰动更新,从而提高算法的全局探索能力和局部开发能力。

2. 多阈值图像分割模型

2.1. 多阈值图像分割问题描述

多阈值图像分割是一种常用的灰度图像分割方法[4],其基本思想是根据图像灰度分布选择多个阈值,并利用这些阈值将图像划分为若干不同的灰度区域。与单阈值分割方法相比,多阈值分割能够更好地处理灰度层次较多、区域结构较复杂的图像,因此在医学图像处理、目标检测、遥感图像分析以及工业视觉检测等任务中具有较高的应用价值。

设输入图像为一幅灰度图像,其灰度级范围为 0 到 255。当需要将图像划分为多个区域时,需要确定一组阈值。若阈值数量为 n ,则阈值组合可表示为:

$$\Theta = \{t_1, t_2, \dots, t_n\}, \quad 0 \leq t_1 < t_2 < \dots < t_n \leq L-1 \quad (1)$$

其中, Θ 表示一组候选阈值, L 表示图像灰度级数。

根据式(1)所示的阈值组合,图像可以被划分为 $n+1$ 个灰度区域。阈值组合的选择会直接影响图像分割结果,因此,多阈值图像分割问题的核心是如何快速、准确地搜索到一组最优阈值。

2.2. Kapur 熵目标函数

在多阈值图像分割中,需要通过一定的评价准则判断阈值组合的优劣。本文采用 Kapur 熵作为目标函数。Kapur 熵是一种基于信息熵的阈值选择方法,其基本思想是:当图像被合理分割后,各个分割区域应具有较充分的信息表达能力,整体熵值应尽可能大。对于给定的阈值组合,可计算各个分割区域的信息熵,并将所有区域的信息熵之和作为评价指标。Kapur 熵目标函数可表示为:

$$F(\Theta) = \sum_{c=0}^n H_c \quad (2)$$

式中, $F(\Theta)$ 表示阈值组合 Θ 对应的整体熵值, H_c 表示第 c 个分割区域的信息熵。

Kapur 熵值越大,说明分割后各区域的信息量越充分,区域之间的灰度差异越明显,分割效果通常越好。因此,多阈值图像分割可以看作一个最大化优化问题,其目标是寻找使 Kapur 熵值最大的阈值组合:

$$\Theta^* = \arg \max_{\Theta} F(\Theta) \quad (3)$$

式中, Θ^* 表示最终获得的最优阈值组合。本文利用改进连续蚁群优化算法对式(3)进行求解, 从而实现多阈值图像分割。

3. 连续蚁群优化算法

3.1. 算法基本思想

连续蚁群优化算法是一种面向连续优化问题的群智能优化算法[5]。与传统蚁群算法主要用于离散路径搜索不同, 连续蚁群优化算法通过建立解档案保存当前搜索过程中的优质解, 并根据解档案中候选解的质量分布进行概率采样, 从而不断生成新的候选解。

在多阈值图像分割任务中, 每一个候选解都对应一组阈值组合。算法首先随机生成若干组候选阈值, 并根据 Kapur 熵值评价这些阈值的质量。随后, 较优的阈值组合会被保存在解档案中, 并作为后续搜索的重要参考。设解档案规模为 k , 优化问题维度为 n , 则解档案中的第 l 个候选解可表示为:

$$S_l = \{s_{l,1}, s_{l,2}, \dots, s_{l,n}\} \quad (4)$$

式中, S_l 表示候选解, $s_{l,d}$ 表示该候选解在第 d 个维度上的取值。

随每次迭代后, 算法根据目标函数值对解档案中的候选解进行排序。对于本文采用的 Kapur 熵目标函数, 熵值越大表示候选解质量越高, 排序越靠前的解在后续采样中被选中的概率也越大。

3.2. 解档案权重与选择概率

连续蚁群优化算法通过权重机制控制候选解被选为采样中心的概率。通常情况下, 排名靠前的优质解应具有更高的选择概率, 但排名靠后的解也应保留一定被选择的机会, 以维持算法的搜索多样性。解档案中第 l 个候选解的权重及其选择概率可表示为:

$$w_l = \frac{1}{qk\sqrt{2\pi}} \exp\left(-\frac{(l-1)^2}{2q^2k^2}\right), \quad P_l = \frac{w_l}{\sum_{r=1}^k w_r} \quad (5)$$

式中, w_l 表示候选解的权重, P_l 表示该候选解被选为采样中心的概率, q 为权重分布调节参数, k 为解档案规模。

由式(5)可知, 排序越靠前的解通常具有越大的权重和选择概率。因此, 算法能够更多地利用当前优质解进行搜索。同时, 由于其他候选解仍具有一定概率被选择, 算法也能保持一定的全局搜索能力。

3.3. 高斯采样生成新解

在确定采样中心后, 连续蚁群优化算法通过高斯采样生成新的候选解。高斯采样的核心思想是在当前优质解附近进行随机搜索, 使新解既能继承已有优质解的信息, 又能产生一定变化。新候选解的生成方式可表示为:

$$x_{j,d}^t = s_{l,d}^t + \sigma_{l,d}^t N(0,1) \quad (6)$$

式中, $x_{j,d}^t$ 表示第 t 次迭代中生成的第 j 个新解在第 d 个维度上的取值。 $s_{l,d}^t$ 表示被选中采样中心在该维度上的取值, $\sigma_{l,d}^t$ 表示采样标准差。

采样标准差由解档案中候选解的分布情况决定。当解档案分布较分散时, 标准差较大, 算法搜索范围更广; 当解档案逐渐集中时, 标准差变小, 算法更倾向于局部搜索。

原始连续蚁群优化算法能够通过上述方式完成连续空间搜索，但在多阈值图像分割问题中，随着阈值数量增加，搜索空间会迅速扩大。此时，如果解档案过早集中，算法容易陷入局部最优，导致最终阈值组合并非全局较优解。因此，本文在原始连续蚁群优化算法的基础上引入分布反馈螺旋扰动机制，以进一步提升算法的搜索能力。

4. 分布反馈螺旋扰动连续蚁群优化算法

4.1. 改进思想

针对原始连续蚁群优化算法在复杂阈值搜索中容易早熟收敛的问题，本文提出一种分布反馈螺旋扰动连续蚁群优化算法。该方法的主要思想是在原始 ACOR 高斯采样之后，进一步利用解档案的整体分布信息对新生成的候选解进行扰动修正，使算法能够在全局探索和局部开发之间取得更好的平衡。具体而言，本文的改进主要引入分布反馈参考点。该参考点由当前最优解和解档案分布中心共同决定，能够避免算法过度依赖单一最优解，从而降低早熟收敛风险。并引入螺旋扰动机制。传统的线性搜索方式容易使候选解沿固定方向移动，而螺旋扰动能够使候选解围绕参考点进行非线性搜索，增加搜索路径的灵活性。最后引入档案差分扰动和随机扰动。档案差分扰动能够利用不同候选解之间的差异产生新的搜索方向，随机扰动则能够增强算法跳出局部最优的能力。

4.2. 分布反馈参考点构建

在连续蚁群优化算法中，当前最优解能够反映目前搜索到的较优区域，而解档案分布中心能够反映整个种群的搜索状态。若只依赖当前最优解，算法容易快速集中到局部区域；若只依赖分布中心，则可能降低对优质区域的开发能力。因此，本文首先计算当前解档案的分布中心：

$$\bar{S}^t = \frac{1}{k} \sum_{l=1}^k S_l^t \quad (7)$$

式中， \bar{S}^t 表示第 t 次迭代时解档案的分布中心， S_l^t 表示当前解档案中的第 l 个候选解， k 表示解档案规模。

在此基础上，构建分布反馈参考点：

$$R^t = \chi_t S_1^t + (1 - \chi_t) \bar{S}^t \quad (8)$$

式中， R^t 表示迭代时的分布反馈参考点， S_1^t 表示当前解档案中的最优解， χ_t 表示动态调节因子。动态调节因子设置为

$$\chi_t = \left(\frac{t}{T} \right)^\lambda \quad (9)$$

式中， T 表示最大迭代次数， λ 为非线性调节参数，用于控制参考点由解档案分布中心向当前最优解转移的速度，默认设为 2.0。当 t 较小时， χ_t 较小，参考点更接近解档案分布中心，有利于保持全局探索能力；随着迭代进行， χ_t 逐渐增大，参考点逐步靠近当前最优解，从而增强算法后期的局部开发能力。

在迭代初期，动态调节因子较小，参考点更接近解档案分布中心，此时算法更注重全局探索；随着迭代次数增加，动态调节因子逐渐增大，参考点逐渐靠近当前最优解，此时算法逐步增强局部开发能力。通过这种方式，算法能够在不同搜索阶段自适应调整搜索方向。

4.3. 分布反馈螺旋扰动算子

在获得分布反馈参考点后，本文对原始 ACOR 采样得到的新解进行进一步扰动更新。设计的分布反

反馈螺旋扰动算子如下：

$$\tilde{X}_j^t = R^t + e^{b\ell} \cos(2\pi\ell)(X_j^t - R^t) + \eta_t r(S_a^t - S_b^t) + \delta_t D^t C \quad (10)$$

式中， b 表示螺旋形状控制参数，默认设置为 1.0， $\ell \sim U(-1,1)$ 表示随机变量， S_a^t 和 S_b^t 表示从当前解档案中随机选择的两个不同候选解， r 表示 0 到 1 之间的随机数， D^t 表示当前解档案的离散程度，定义为 $D^t = \{D_1^t, D_2^t, \dots, D_n^t\}$ ，其中 $D_d^t = \frac{1}{k} \sum_{i=1}^k |s_{i,d}^t - \bar{s}_d^t|$ ，用于衡量第 d 维上候选解的平均分散程度； C 表示柯西随机扰动， η_t 和 δ_t 分别表示差分扰动强度和随机扰动强度。

式(8)主要由三部分组成。第一部分为螺旋扰动项，用于使候选解围绕参考点进行非线性移动。该项能够避免候选解仅沿单一方向靠近参考位置，从而提高局部搜索的灵活性。第二部分为档案差分扰动项，用于利用不同候选解之间的差异生成新的搜索方向。该项有助于增强算法的全局探索能力。第三部分为随机扰动项，用于在搜索过程中引入一定的不确定性，使算法具有跳出局部最优的能力。为了使算法在迭代前期具有较强探索能力、在迭代后期具有较强开发能力，本文对扰动强度进行动态控制：

$$\eta_t = \eta_0 \left(1 - \frac{t}{T}\right), \delta_t = \delta_0 \left(1 - \frac{t}{T}\right) \quad (11)$$

式中， η_0 和 δ_0 表示分别表示初始差分扰动强度和初始随机扰动强度。随着迭代次数增加，两个扰动系数逐渐减小，使算法由大范围搜索逐渐转向精细搜索。

综上，本文所提出的分布反馈螺旋扰动算子能够充分利用解档案中的最优解、分布中心和候选解差异信息。与原始连续蚁群优化算法相比，该方法能够在保持局部开发能力的同时增强搜索多样性，从而提高多阈值图像分割任务中的寻优能力。

5. 实验结果与分析

为验证本文所提出的分布反馈螺旋扰动连续蚁群优化算法的有效性，本章从两个方面开展实验分析。首先，在标准优化测试函数上对本文算法与原始连续蚁群优化算法进行对比，以验证所提出扰动机制对算法全局寻优能力和收敛性能的提升效果。随后，将本文算法应用于多阈值图像分割任务，并在结肠癌病理图像数据集上进行实验，以进一步验证算法在实际图像分割任务中的应用性能。所有实验均在相同运行条件下进行，以保证实验对比的公平性。

5.1. 标准测试函数实验

为了验证 DFSACO 在连续优化问题中的寻优能力，本文选取 CEC2017 和 CEC2022 标准测试函数集进行实验[6]。CEC2017 测试函数集包含 29 个不同类型的测试函数，能够较全面地考察算法在单峰、多峰、混合和组合优化问题中的性能。CEC2022 测试函数集包含 12 个测试函数，函数结构更加紧凑，可进一步用于验证算法在不同优化场景下的泛化能力。

在 CEC2017 测试中，本文分别设置问题维度为 30、50 和 100；在 CEC2022 测试中，分别设置问题维度为 10 和 20。为了减少随机因素对实验结果的影响，每个测试函数均独立运行 30 次，并统计平均结果。同时，本文采用 Wilcoxon Signed-Rank Test (WSRT)符号秩检验对 DFSACO 和 ACOR 的实验结果进行显著性分析[7]。

表 1 给出了 DFSACO 与 ACOR 在 CEC2017 和 CEC2022 测试函数集上的 WSRT 统计结果。其中，R+/R-/R= 分别表示 DFSACO 显著优于、显著劣于以及与对比算法无显著差异的函数数量。

从表 1 可以看出，DFSACO 在大多数测试函数上均优于原始 ACOR。在 CEC2017 测试函数集中，当问题维度为 30 时，DFSACO 在 22 个函数上显著优于 ACOR，仅在 5 个函数上表现略差，并在 2 个函数

上无显著差异。当问题维度增加到 50 和 100 时, DFSACO 的优势更加明显, 尤其在 100 维测试中, DFSACO 在全部 28 个测试函数上均优于 ACOR。

Table 1. Results of the WSRT comparing DFSACO and ACOR on CEC2017 and CEC2022
表 1. DFSACO 与 ACOR 在 CEC2017 和 CEC2022 上的 WSRT 对比结果

算法	CEC2017			CEC2022	
	Dim = 30	Dim = 50	Dim = 100	Dim = 10	Dim = 20
DFSACO	~	~	~		
ACOR	22/5/2	25/2/2	28/0/1	7/2/3	9/2/1

在 CEC2022 测试函数集中, 虽然测试函数数量相对较少, 但 DFSACO 仍然表现出较好的优化性能。在 10 维和 20 维条件下, DFSACO 分别在 7 个和 9 个函数上显著优于 ACOR, 说明本文提出的分布反馈螺旋扰动机制不仅能够提升算法在传统测试函数上的搜索能力, 也具有一定的泛化能力。

总体来看, 随着问题维度的增加, ACOR 更容易受到搜索空间扩大的影响, 出现收敛精度下降或陷入局部最优的问题。而 DFSACO 通过引入分布反馈参考点、螺旋扰动和档案差分扰动, 能够更充分地利用解档案中的分布信息, 增强算法在复杂搜索空间中的探索能力。因此, DFSACO 在高维优化问题中表现出更加稳定的优化性能。

5.2. 多阈值图像分割实验

在验证 DFSACO 的优化性能后, 本文进一步将其应用于多阈值图像分割任务。实验采用基于 Kapur 熵的多阈值分割模型, 将阈值组合搜索问题转化为连续优化问题, 并利用 DFSACO 搜索最优阈值组合。

本文选取 LC25000 数据集[8]中的 9 张结肠癌病理图像作为实验对象, 分别记为 A-I。所有图像统一调整为 768×768 大小, 并转换为灰度图像进行多阈值分割实验。

为了考察算法在不同分割复杂度下的性能, 本文设置 6 个不同阈值层级, 分别为 5、6、10、15、20 和 30。阈值数量越多, 表示图像被划分为更多灰度区域, 优化搜索空间也随之增大。因此, 不同阈值层级能够用于验证算法在不同复杂度图像分割任务中的稳定性和搜索能力。在实验中, DFSACO 与 ACOR 在相同条件下运行。最大评价次数设置为 2000, 每组实验独立运行 30 次, 并统计各算法在不同阈值层级下的平均表现。

为全面评价多阈值图像分割效果, 本文采用 PSNR [9]、SSIM [10]和 FSIM [11]三个指标作为客观评价指标。

PSNR 用于衡量分割图像与原始图像之间的差异程度。一般而言, PSNR 值越高, 说明分割图像与原始图像之间的误差越小, 图像重建质量越高。SSIM 从亮度、对比度和结构三个方面评价图像之间的相似性。相比 PSNR, SSIM 更加符合人眼视觉感知特点。SSIM 值越高, 说明图像结构保持效果越好。FSIM 基于特征相似性评价图像质量, 主要利用相位一致性和梯度幅值等特征衡量图像之间的相似程度。FSIM 值越高, 说明图像的关键结构和边缘特征保持得越好。为了进一步分析算法之间的显著性差异, 本文同样采用 WSRT 对不同算法在 9 张图像上的结果进行统计分析, 并给出平均排名结果。

表 2 给出了 DFSACO 与 ACOR 在不同阈值层级下的 PSNR 对比结果。其中, R+/R-/R= 表示 DFSACO 相对于 ACOR 在 9 张测试图像上的显著性比较结果; Mean 表示平均排名; Rank 表示综合排名。从表 2 可以看出, 在 PSNR 指标上, DFSACO 在所有阈值层级下均取得了优于 ACOR 的综合排名。当阈值数量较低时, 例如阈值层级为 5 和 6 时, DFSACO 已经表现出一定优势, 但仍存在少量图像上与 ACOR 差异

不明显的情况。随着阈值数量增加，DFSACO 的优势逐渐扩大。当阈值层级达到 10 及以上时，DFSACO 在大部分图像上均显著优于 ACOR。特别是在阈值层级为 20 和 30 时，DFSACO 在 9 张图像上均取得更优结果，说明本文算法在复杂阈值搜索场景下具有更强的优化能力。这主要是因为当阈值数量增加时，候选阈值组合的搜索空间迅速扩大，原始 ACOR 更容易受到解档案过早集中的影响，从而降低搜索多样性。而 DFSACO 通过分布反馈螺旋扰动机制增强了候选解更新过程中的搜索灵活性，因此能够获得更优的阈值组合。

Table 2. The PSNR comparison results at different threshold levels
表 2. 不同阈值层级下的 PSNR 对比结果

Threshold	指标	DFSACO	ACOR
5	R+/R-/R=	~	4/3/2
	Mean	1.4444	1.5556
	Rank	1	2
6	R+/R-/R=	~	5/2/2
	Mean	1.3333	1.6667
	Rank	1	2
10	R+/R-/R=	~	6/1/2
	Mean	1.2222	1.7778
	Rank	1	2
15	R+/R-/R=	~	8/0/1
	Mean	1.0556	1.9444
	Rank	1	2
20	R+/R-/R=	~	9/0/0
	Mean	1.0000	2.0000
	Rank	1	2
30	R+/R-/R=	~	9/0/0
	Mean	1.0000	2.0000
	Rank	1	2

从表 3 可以看出，DFSACO 在 SSIM 指标上同样整体优于 ACOR。SSIM 主要反映图像结构信息的保持程度，因此该结果说明 DFSACO 搜索得到的阈值组合能够更好地保持病理图像中的组织结构和区域边界信息。在较低阈值层级下，图像被划分的区域数量较少，不同算法得到的分割结果差异相对有限，因此 DFSACO 与 ACOR 之间的优势并不十分明显。而当阈值层级逐渐增加后，图像灰度区域被划分得更加细致，算法对阈值搜索精度的要求更高。此时，DFSACO 的分布反馈机制能够更有效地引导候选解向优质区域移动，从而在 SSIM 指标上取得更好的结果。说明本文算法在高阈值分割任务中具有更强的结构保持能力和稳定性。

Table 3. The SSIM comparison results at different threshold levels
表 3. 不同阈值层级下的 SSIM 对比结果

Threshold	指标	DFSACO	ACOR
5	R+/R-/R=	~	4/3/2
	Mean	1.4444	1.5556
	Rank	1	2
6	R+/R-/R=	~	5/2/2
	Mean	1.3333	1.6667
	Rank	1	2
10	R+/R-/R=	~	6/1/2
	Mean	1.2222	1.7778
	Rank	1	2
15	R+/R-/R=	~	7/1/1
	Mean	1.1667	1.8333
	Rank	1	2
20	R+/R-/R=	~	7/1/1
	Mean	1.1667	1.8333
	Rank	1	2
30	R+/R-/R=	~	8/0/1
	Mean	1.0556	1.9444
	Rank	1	2

从表 4 可以看出, DFSACO 在 FSIM 指标上仍然保持稳定优势。FSIM 更关注图像中的边缘、纹理和结构特征, 因此该指标能够较好地反映分割结果对病理图像关键结构的保持能力。在结肠癌病理图像中, 细胞结构、组织边界和纹理变化较为复杂。如果阈值选择不合理, 容易导致边缘细节丢失或区域划分不充分。ACOR 依赖高斯采样生成新解, 在高阈值层级下容易出现搜索不充分的问题。相比之下, DFSACO 在候选解更新过程中引入了螺旋扰动和档案差分扰动, 能够更充分地探索阈值空间, 从而获得更适合图像结构表达的阈值组合。从整体趋势来看, 随着阈值数量的增加, DFSACO 相对于 ACOR 的优势更加明显。这与前文标准测试函数实验结果一致, 即本文算法在复杂优化问题中更能够体现其搜索能力优势。

在标准测试函数实验中, DFSACO 在 CEC2017 和 CEC2022 多数测试函数上取得更优结果, 说明本文提出的分布反馈螺旋扰动机制能够有效提升算法的全局搜索能力和收敛精度。特别是在高维 CEC2017 测试中, DFSACO 的优势更加明显, 表明该方法适用于复杂连续优化问题。

在多阈值图像分割实验中, DFSACO 在 PSNR、SSIM 和 FSIM 三个评价指标上均优于 ACOR。尤其是在阈值数量较多的情况下, DFSACO 能够保持更稳定的优势。这说明本文算法能够在复杂阈值搜索空间中获得更优的阈值组合, 从而提高图像分割质量。

造成这一现象的主要原因在于, 原始 ACOR 在迭代过程中主要依赖解档案中的优质解进行高斯采样, 当候选解逐渐集中后, 算法搜索范围会不断缩小, 容易陷入局部最优。而 DFSACO 通过分布反馈参考点综合利用当前最优解和解档案整体分布信息, 使算法不会过早依赖单一最优解。同时, 螺旋扰动增强了候选解局部搜索路径的灵活性, 档案差分扰动和随机扰动进一步提高了算法跳出局部区域的能力。因此,

DFSACO 在优化精度和分割质量方面均表现出更好的性能。

Table 4. The FSIM comparison results at different threshold levels

表 4. 不同阈值层级下的 FSIM 对比结果

Threshold	指标	DFSACO	ACOR
5	R+/R-/R=	~	5/2/2
	Mean	1.3333	1.6667
	Rank	1	2
6	R+/R-/R=	~	5/2/2
	Mean	1.3333	1.6667
	Rank	1	2
10	R+/R-/R=	~	6/2/1
	Mean	1.2778	1.7222
	Rank	1	2
15	R+/R-/R=	~	6/1/2
	Mean	1.2222	1.7778
	Rank	1	2
20	R+/R-/R=	~	7/1/1
	Mean	1.1667	1.8333
	Rank	1	2
30	R+/R-/R=	~	7/1/1
	Mean	1.1667	1.8333
	Rank	1	2

6. 结论

本文针对多阈值图像分割中阈值搜索空间大、传统穷举方法计算成本高以及原始连续蚁群优化算法容易出现搜索多样性下降和局部最优等问题，提出了一种基于分布反馈螺旋扰动的改进连续蚁群优化算法 DFSACO。该方法在原始 ACOR 高斯采样机制的基础上，引入分布反馈参考点、螺旋扰动、档案差分扰动和自适应随机扰动机制，以提高算法在复杂连续搜索空间中的寻优能力。

DFSACO 性能提升的主要原因在于以下几个方面。首先，分布反馈参考点同时结合当前最优解和解档案分布中心，使算法在搜索过程中不会过早依赖单一最优解，从而在一定程度上缓解早熟收敛问题。其次，螺旋扰动机制使候选解围绕参考点进行非线性移动，相比简单的线性搜索方式，能够增强局部搜索路径的灵活性。再次，档案差分扰动利用不同候选解之间的差异生成新的搜索方向，有助于维持种群多样性。最后，基于档案离散度的随机扰动能够根据当前搜索状态自适应调整扰动幅度，使算法在前期保持较强探索能力，在后期逐渐转向稳定开发。

实验结果表明，DFSACO 在 CEC2017 和 CEC2022 标准测试函数集上整体优于原始 ACOR，尤其在较高维度优化问题中表现出更稳定的搜索能力。进一步地，本文将 DFSACO 应用于结肠癌病理图像的多阈值分割任务，并在不同阈值层级下进行实验分析。结果表明，DFSACO 在 PSNR、SSIM 和 FSIM 等评价指标上整体取得优于 ACOR 的结果，说明本文方法能够搜索到更合理的阈值组合，并提升多阈值图像

分割质量。同时，本文仍存在一定局限性。一些参数主要依据经验范围和预实验进行设置，虽然本文给出了推荐取值和参考范围，但更系统的参数敏感性实验仍有待进一步开展。

未来研究将从以下几个方面展开：一是设计更加自适应的参数调节机制，使扰动强度和反馈因子能够根据搜索状态自动调整，减少人工参数设置的影响；二是进一步开展消融实验和参数敏感性分析，量化不同扰动项对算法性能的贡献；三是将 DFSACO 扩展到二维直方图分割、彩色图像分割以及多模态医学图像分割任务中，以进一步提升算法的应用价值和泛化能力。

参考文献

- [1] 王野, 李钦奉. 基于改进 OTSU 的煤尘颗粒图像分割算法研究[J]. 计算机与数字工程, 2023, 51(8): 1871-1875.
- [2] 马军, 鲍日洋, 彭晓旭, 等. 基于粒子群优化算法的 Kapur 熵多阈值图像分割[J]. 科技创新与生产力, 2018(11): 79-81, 85.
- [3] 涂涛涛, 马强. 社会核算矩阵平衡方法研究——再议最小二乘交叉熵法[J]. 数量经济技术经济研究, 2021, 38(6): 166-180.
- [4] 任永强, 汪超, 韩冲. 基于改进灰狼优化算法的多阈值图像分割研究[J]. 合肥工业大学学报(自然科学版), 2026, 49(3): 330-336.
- [5] Dorigo, M. and Di Caro, G. (1999) Ant Colony Optimization: A New Meta-Heuristic. *Proceedings of the 1999 Congress on Evolutionary Computation-CEC99 (Cat. No. 99TH8406)*, Washington, 6-9 July 1999, 1470-1477. <https://doi.org/10.1109/cec.1999.782657>
- [6] Wu, G., Mallipeddi, R. and Suganthan, P.N. (2017) Problem Definitions and Evaluation Criteria for the CEC 2017 Competition on Constrained Real-Parameter Optimization. National University of Defense Technology, Changsha, Hunan, PR China and Kyungpook National University, Daegu, South Korea and Nanyang Technological University, Singapore, Technical Report.
- [7] Derrac, J., García, S., Molina, D. and Herrera, F. (2011) A Practical Tutorial on the Use of Nonparametric Statistical Tests as a Methodology for Comparing Evolutionary and Swarm Intelligence Algorithms. *Swarm and Evolutionary Computation*, 1, 3-18. <https://doi.org/10.1016/j.swevo.2011.02.002>
- [8] Borkowski, A.A., Bui, M.M., Thomas, L.B., Wilson, C.P., DeLand, L.A. and Mastorides, S.M. (2019) Lung and Colon Cancer Histopathological Image Dataset (LC25000). arXiv: 1912.12142.
- [9] Huynh-Thu, Q. and Ghanbari, M. (2008) Scope of Validity of PSNR in Image/Video Quality Assessment. *Electronics Letters*, 44, 800-801. <https://doi.org/10.1049/el:20080522>
- [10] Wang, Z., Bovik, A.C., Sheikh, H.R. and Simoncelli, E.P. (2004) Image Quality Assessment: From Error Visibility to Structural Similarity. *IEEE Transactions on Image Processing*, 13, 600-612. <https://doi.org/10.1109/tip.2003.819861>
- [11] Zhang, L., Zhang, L., Mou, X.Q. and Zhang, D. (2011) FSIM: A Feature Similarity Index for Image Quality Assessment. *IEEE Transactions on Image Processing*, 20, 2378-2386. <https://doi.org/10.1109/tip.2011.2109730>