

Journal of System Simulation

Volume 32 | Issue 10

Article 5

10-14-2020

Nature Computation of Self-Adaptive Dynamic Control Strategy of Population Grouping

Wanlu Ni

School of Computer Science and Information Engineering, Harbin Normal University, Harbin 150025, China;

Weidong Ji

School of Computer Science and Information Engineering, Harbin Normal University, Harbin 150025, China;

Xiaoqing Sun

School of Computer Science and Information Engineering, Harbin Normal University, Harbin 150025, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>

 Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Nature Computation of Self-Adaptive Dynamic Control Strategy of Population Grouping

Abstract

Abstract: Multi-population optimization method can solve the optimization difficulty caused by the increase of data volume, but the existing population grouping is carried out by means of random grouping or artificial setting, which doesn't take particle trajectories into full consideration. In view of the problem a *self-adaptive dynamic control strategy of population grouping is proposed, which uses Gaussian fitting function as the reference curve of population grouping and divides sub populations according to the function's monotone interval. For particles with the trend of crossing the upper boundary of sub populations, the contrarian strategy is adopted to maintain the population diversity and improve the convergence speed.* The tactics does not rely on concrete evolution procedure of the algorithm, and the strategy is applicable to all nature computation means, based on population optimization. The experimental results show the effectiveness and universality of the algorithm.

Keywords

population grouping, dynamic control, gaussian fitting, contrarian strategy, nature computation

Recommended Citation

Ni Wanlu, Ji Weidong, Sun Xiaoqing. Nature Computation of Self-Adaptive Dynamic Control Strategy of Population Grouping[J]. Journal of System Simulation, 2020, 32(10): 1884-1894.

自适应动态控制种群分组的自然计算方法

倪婉璐, 季伟东, 孙小晴

(哈尔滨师范大学 计算机科学与信息工程学院, 黑龙江 哈尔滨 150025)

摘要: 多种群优化方法可以解决数据量增大导致的优化难度增加的问题, 现有的种群分组都采用随机分组或人为设定的方法, 没有充分考虑粒子运动轨迹。针对此问题, 提出一种种群分组自适应动态控制策略, 使用高斯拟合函数作为种群分组的参考曲线, 根据函数单调区间划分子种群; 对于有越过子种群上界趋势的粒子采用逆向策略, 保持种群多样性同时提高收敛速度。该策略不依赖于算法的具体进化过程, 适用于所有基于种群优化的自然计算方法。验证实验结果表明了所提新算法的有效性和普适性。

关键词: 种群分组; 动态控制; 高斯拟合; 逆向策略; 自然计算

中图分类号: TP301 文献标识码: A 文章编号: 1004-731X (2020) 10-1884-11

DOI: 10.16182/j.issn1004731x.joss.20-FZ0327

Nature Computation of Self-Adaptive Dynamic Control Strategy of Population Grouping

Ni Wanlu, Ji Weidong, Sun Xiaoqing

(School of Computer Science and Information Engineering, Harbin Normal University, Harbin 150025, China)

Abstract: Multi-population optimization method can solve the optimization difficulty caused by the increase of data volume, but the existing population grouping is carried out by means of random grouping or artificial setting, which doesn't take particle trajectories into full consideration. In view of the problem a self-adaptive dynamic control strategy of population grouping is proposed, which uses Gaussian fitting function as the reference curve of population grouping and divides sub populations according to the function's monotone interval. For particles with the trend of crossing the upper boundary of sub populations, the contrarian strategy is adopted to maintain the population diversity and improve the convergence speed. The tactics does not rely on concrete evolution procedure of the algorithm, and the strategy is applicable to all nature computation means, based on population optimization. The experimental results show the effectiveness and universality of the algorithm.

Keywords: population grouping; dynamic control; gaussian fitting; contrarian strategy; nature computation

引言

自然计算(natural computation)是指受自然现



收稿日期: 2020-03-29 修回日期: 2020-06-09;
基金项目: 国家自然科学基金(31971015), 哈尔滨市科技局科技创新人才研究专项(2017RAQXJ050);
作者简介: 倪婉璐(1996-), 女, 江苏南通, 硕士生, 研究方向为群体智能; 季伟东(通讯作者 1978-), 黑龙江哈尔滨, 博士, 教授, 研究方向为大数据、群体智能。

象启发而发展起来的智能算法, 如人工神经网络、进化计算、群智能、人工免疫系统、量子计算等^[1]。自然计算具有自组织、自学习、自适应能力, 能够学习运用自然规律、模拟自然系统甚至社会系统的演变过程, 在复杂优化问题求解、智能控制与机器人控制、网络通信与信息安全、社会经济、生态环境、航空航天与军事等领域的应用非常广泛^[2]。

自然计算反映了“群体行为”的智能化信息处理机制以及内在的并行机制, 在此理论基础上进行种群分组, 将较大规模种群划分成子种群并行优化, 对算法的寻优结果和计算成本有较大的影响。随着数据量的增大, 优化难度亦不断增加, 多种群的优化策略成为研究热点。基于模拟退火机制的多种群并行遗传算法^[3], 直接初始化 M 个子种群且种群中粒子数固定并相同, 再通过交叉、变异等操作, 直至产生 M 个新的子种群; 自适应小生态遗传算法的理论分析和加速技术^[4]中将规模为 N 的种群随机分成 $N/2$ 对父代, 对其进行交叉、变异后产生子代, 再通过欧氏距离计算个体相似度进行替换, 形成新的小生态; 基于精英协同的多种群分布估计算法^[5]中 S 个子种群划分仍然是随机产生, 但子种群粒子的确认则是将种群粒子归于第一象限, 按单位超球面将第一象限均匀分成 S 个中间向量, 通过计算粒子与中间向量的夹角确定该粒子归为哪个子种群; 基于多种群的自适应迁移 PSO 算法(MSMPSO)^[6]是对初始种群等分, 产生 3 个子种群, 为各子种群分配相应的加速因子; 多种群协方差学习差分进化算法^[7], 通过多种群随机策略, 随机划分子种群。这些方法在一定程度上平衡了算法在进化过程中的全局搜索和局部开发能力, 并克服早熟收敛等缺点, 降低了算法的计算成本, 但种群分组大方向上都是基于随机策略, 只在子种群内粒子的确定方面存在差异性, 没有充分考虑粒子的运动轨迹。

本文综合考虑粒子的运行轨迹以 P_i 和 P_g 的加权平均值为中心进行振荡^[8]的特征, 提出一种普适的自适应动态控制种群分组的策略(self-adaptive dynamic control strategy of population grouping, 简称 SaDCPG)。将该策略基于高斯拟合曲线划分子种群及对存在越界趋势的个体采用逆向策略, 运用到 2 种不同的自然计算方法中, 采用标准测试函数验证文中提出的自适应动态控制策略的综合性能, 即普适性、有效性、鲁棒性。

1 种群分组自适应动态控制策略

种群分组主要解决 3 个问题, 即种群何时分组、划分几组和如何分组。

第 1 个问题是初始化种群后, 是否进行一定次数的迭代再进行划分子种群;

第 2 个问题是划分子种群的数目由什么来确定;

第 3 个问题是依据什么来具体划分子种群。

下面详细介绍所提出的种群分组自适应动态控制策略对这 3 个问题各自的解决办法。

1.1 基于高斯函数的曲线拟合

自然计算通过模拟自然界生物种群机理, 利用种群内个体间的信息交流, 协同合作寻找最优解, 根据中心极限定理可知, 自然界中种群的随机性可用正态分布或近似正态分布来描述。Clerc 和 Kennedy 在文献[8]中对标准粒子群算法中的粒子运行轨迹进行了分析, 指出粒子的运行轨迹以 P_i 和 P_g 的加权平均值为中心进行振荡。Kennedy^[9]在此基础上对粒子轨迹振荡的中心和幅值进行了进一步研究表明, 粒子位置的更新可以直接通过高斯分布采样得到^[10]。

高斯分布(Gaussian distribution)又名正态分布(Normal distribution), 作为数学、物理中的重要概率知识, 在计算机视觉、图像处理中具有较高的普适性。由局部正态分布拟合能量驱动的活动轮廓^[11], 以及 2016 年提出的基于高斯拟合的高光谱影像配准算法^[12]、采用高斯拟合的全局阈值算法阈值优化框架^[13], 都较好的结合了高斯拟合技术进行图像分割处理, 极大提高了算法性能。同时, James Kennedy 在文献[9]中的实验证明了标准粒子群算法与高斯版本的粒子群算法相比较而言, 高斯粒子收敛更快, 且高斯版本的算法性能最佳。文献[14]运用了高斯密度函数来拟合随机样本的方法, 这都说明了高斯分布运用在自然计算方法中的有效性。

基于以上分析，在自然计算领域，高斯拟合函数的应用不仅具备较大潜力的普适性，更能提高算法的有效性，因此，本文利用高斯函数拟合曲线作为种群分组的参照物。

1.2 动态控制策略

本文提出一种种群分组(population grouping，简称 PG)方法，其主要思想为：种群连续 K 代更新后，依据个体适应度值进行高斯拟合，运用数学函数中单调区间的判定规则对拟合曲线进行区间划分，存在于 2 个波峰间的个体定义为一个子种群；通过计算拟合函数的波峰数确定种群划分的子种群数目。种群划分完成后，进行正式迭代寻优，子种群每完成一次迭代，就进行越界判定，若子种群内部分个体存在越界趋势，则对该部分个体采取逆向策略。其中， K 是 PG 的拟合阈值，种群连续 K 代更新使得拟合曲线与目标函数曲线

有较强的关联度，但为保证拟合后分组的意义， K 的取值应该较小。PG 依据的是高斯拟合曲线单调区间的数学判定准则进行分组的，综合了粒子运行轨迹的特性及严谨的数学判定规则，使其更具科学性，逻辑性。

PG 方法中存在几点不足：

- (1) 人为控制高斯拟合函数的项数，函数项数越多，拟合度越高，从而大多情况下子种群数增加，提高算法时间复杂度；
- (2) 若拟合阈值 K 过小，会产生欠拟合，反之， K 越大，则过拟合，削弱了分组的意义。

因此，为平衡子种群数目和算法的时间成本，高斯拟合函数的项数取 6，通过实验对比分析，拟合阈值为 10。

图 1 是动态控制策略的流程图， $fit_O^g(j)$ 表示第 O 个子种群中的第 j 个粒子在第 g 代的适应度值。

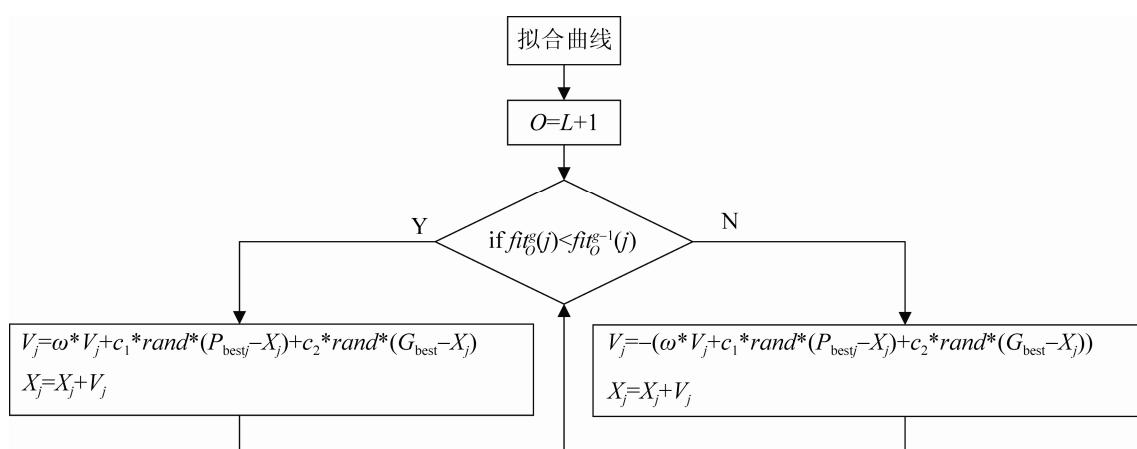


图 1 动态控制策略流程
Fig. 1 Flowchart of dynamic control strategy

1.3 种群分组与越界个体的逆向策略

种群分组不仅能平衡种群多样性和算法的计算成本，而且如果恰当的运用逆向策略，能够加快收敛速度，有效提高算法性能。下面分别详细介绍本文方法中的种群分组和逆向策略。

1.3.1 种群分组

传统的自然计算随着迭代的进行，种群内的个

体或逐渐接近，或由于“适者生存”的原则而减少，降低了种群的多样性，为提高算法的种群多样性，将种群划分出若干个子种群，同时每个子种群独立优化。本文中的种群分组是基于数学函数中单调区间的规则进行的，根据拟合曲线的峰值个数 L 确定应该划分的 $L+1$ 个子种群以及波峰值对应位 $locs$ 来界定子种群的个体数量，如第 L 个子种群个体数量为 $locs(L)-locs(L-1)$ 。如图 2 所示，横轴代表当

前状态下的第 i 个个体, 纵轴表示个体适应度值, 黑色虚线对应拟合曲线的波峰, 共有 5 个波峰, 以波峰为边界, 居于界限内的粒子为一个子种群, 则存在 6 个子种群。

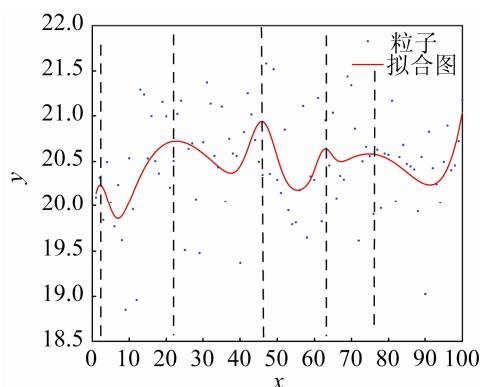


图 2 子种群划分方法
Fig. 2 Subpopulation division method

1.3.2 越界个体的逆向策略

在种群迭代过程中, 若子种群中的个体存在越界的趋势, 即该个体适应度值超过子种群上界, 为使子种群快速收敛到当前区间内的最优值, 对存在越界趋势的个体逆向牵引。然而, 大多反向学习算法都是基于较优粒子位置的变异, 如一种精英反向学习的粒子群优化算法 (EOPSO)^[15]、一种最优粒子逐维变异的粒子群优化算法^[16]。

本文逆向策略的主要思想是: 子种群每次迭代后都进行越界判定, 在大多数个体趋向最优解的情况下, 对适应度值趋向波峰或越过波峰的个体加反向速度。本文中种群分组后独立寻优, 一子种群的 n 个个体在 2 个波峰间, 寻优则是找到波谷, 每次迭代, 大多个体更趋向于波谷, 少数个体较之前位置更趋向于波峰, 则赋予这少数个体一个相反的速度方向, 如式(1)所示, 使得每一次的迭代过程中, 个体的速度方向都倾向于波谷, 加快算法的收敛速度。

$$V_j = -[\omega \times V_j + c_1 \times \text{rand} \times (P_{\text{best}} - X_j) + c_2 \times \text{rand} \times (G_{\text{best}} - X_j)] \quad (1)$$

1.4 算法的实现策略

算法 自适应动态控制种群分组的自然计算方法

step 1: 设置 PS_{\max} , PS_{\min} , K 。初始化种群 $\text{pop} \in [\text{pop}_{\max}, \text{pop}_{\min}]$, 计算初始化种群所有个体的适应度值 $fitness$, 令 $fitness_{best} \leftarrow \min(fitness)$;

step 2: 先将种群迭代 K 次, 拟合曲线, 计算出波峰个数 L 和各波峰值对应位 $locs$, 划分子种群;

step 3: 计算各子种群所有个体适应度值、个体极值、全体极值;

step 4: 若达到算法终止条件, 则返回最优解; 否则, 转 step 5;

step 5: 对 $L+1$ 个子种群进行一次迭代;

step 6: 若当前个体适应度值优于上一代的适应度值, 即 $fit_O^g(j) < fit_O^{g-1}(j)$, 则按常规继续迭代比较, 否则, 根据公式(1)更新个体;

step 7: $g \leftarrow g + 1$, 转 step 4。

2 仿真实验与结果分析

为检验本文算法 SaDCPG 的综合性能, 将 SaDCPG 运用到 2 种不同的自然计算方法中: 一种是粒子群优化算法 (PSO)^[17], 另一种是遗传算法 (GA)^[18]。对应的 2 种新算法是自适应动态控制种群分组的粒子群优化算法 (SaDCPG+PSO) 和自适应动态控制种群分组的遗传算法 (SaDCPG+GA), 并采用通用标准测试函数 $F_1 \sim F_{12}$ 来验证 SaDCPG 对不同算法的改进效果, 测试函数如表 1 所示。所有测试函数的维数均取 30 维。各算法对测试函数分别执行 20 次, 取平均结果。

表1 标准测试函数
Tab. 1 Standard test function

测试 函数	函数名称	函数公式	定义域	最优值
F ₁	Sphere	$F_1 = \sum_{i=1}^D x_i^2$	[-100,100]	0
F ₂	Rosenbrock's function	$F_2 = (x_1 - 1)^2 + \sum_{i=1}^D i * (2x_i^2 - x_{i-1})^2$	[-5,10]	0
F ₃	dixon-price	$F_3 = \sum_{i=1}^D x_i ^{i+1}$	[-10,10]	0
F ₄	sum of different powers	$F_4 = -a * \exp\left(-b \sqrt{\frac{1}{D} \sum_{i=1}^D x_i^2}\right) - \exp\left(\frac{1}{D} \sum_{i=1}^D \cos(cx_i)\right) + a + \exp(1)$ $a = 20, b = 0.2, c = 2\pi$	[-1,1]	0
F ₅	Ackley	$F_5 = \sum_{i=1}^D (x_i^2 - 10 * \cos(2 * \pi * x_i) + 10)$	[-32.768, 32.768]	0
F ₆	Rastrigin	$F_6 = \sum_{i=1}^D \frac{x_i^2}{4000} - \prod_{i=1}^D \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	[-5.12, 5.12]	0
F ₇	Griewank	$F_7 = \sin^2(\pi \omega_l) + \sum_{i=1}^{D-1} (\omega_i - 1)^2 [1 + 10 \sin^2(\pi \omega_i + 1)] + (\omega_D - 1)^2 [1 + \sin^2(2\pi \omega_D)]$ $\omega_i = 1 + (\omega_i - 1)/4$	[600,600]	0
F ₈	Powellfunction	$F_8 = 418.9829D - \sum_{i=1}^D x_i \sin(\sqrt{ x_i })$	[0, π]	0
F ₉	levy	$F_9 = \sum_{i=1}^{D-1} \left[100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2 \right]$	[-10,10]	0
F ₁₀	Schwefel function	$F_{10} = \sum_{i=1}^{D/4} \left[(x_{4i-3} + 10x_{4i-2})^2 + 5(x_{4i-1} - x_{4i})^2 + (x_{4i-2} - 2x_{4i-1})^4 + 10(x_{4i-3} - x_{4i})^4 \right]$	[500,500]	0
F ₁₁	sum squares	$F_{11} = \sum_{i=1}^D i x_i^2$	[-10,10]	0
F ₁₂	zakharov	$F_{12} = \sum_{i=1}^D x_i^2 + \left(\sum_{i=1}^D 0.5ix_i \right)^2 + \left(\sum_{i=1}^D 0.5ix_i \right)^4$	[-5,10]	0

2.1 参数设置

改进的 PSO 中涉及的参数有 3 个，分别是种群规模、惯性权重、学习因子。按照文献[15]的参数设置，令 $\omega_s=0.4, \omega_e=0.9, c_1=c_2=2$ 。遗传算法中涉及到的参数是种群规模、交叉概率 P_c 、变异概率 P_m ，令 $P_c=0.70, P_m=0.05$ 。本文中涉及的参数有种群规模的下界 PS_{min} 、种群规模的上界 PS_{max} 、拟合阈值 K 。理论上 PS_{min} 可以为 1，但是在本文 SaDCPG 算法中涉及到种群划分，所以本文设置种群规模

PS_{min} 为 4。PSO，GA 中的种群规模以及 SaDCPG 中的 PS_{max} 都设为 100。

2.2 不同改进点实验结果分析

为验证不同方面对 SaDCPG 的改进效果，主要从以下 3 处进行对比分析：

- (1) 不同拟合阈值 K 对算法的影响；
- (2) 人为分组与高斯拟合曲线分组对比；
- (3) 子种群独立并行优化过程中有无采用逆向策略。

在此考虑篇幅问题, 只选用优化经典测试函数 F_2 和 F_5 , 验证 SaDCPG 与 PSO 算法结合的算法的性能。

通过上文对拟合阈值的分析, 若拟合阈值 K 过小, 会产生欠拟合, 反之, K 越大, 则过拟合, 会削弱分组的意义。因此, 我们选取 K 为 0、10、20 分别作用于单峰函数 F_2 和一多峰函数 F_5 。从表 2 的数据结果可以得出对于多峰函数, 拟合阈值的变动不改变最终的寻优结果, 但是从收敛曲线图 3 明显看出算法收敛到最优值的适应度值计算次数不同, $K=10$ 的时候, 多峰函数更早的找到最优值。而对于单峰函数, $K=0$ 时的平均适应度值与全局最优值都是最佳的, 这是由于单峰函数不存在多个最优值点, 直接拟合不易陷入局部最优。之后随着 K 值不断增大, 拟合曲线越接近目标函数曲线, 因此, 最终的收敛结果会更精确。由于种群经

过 K 次迭代后的高斯拟合曲线更加接近目标函数曲线, 但是, 若 K 值无限变大, 则削弱了种群分组的意义, 所以为平衡拟合曲线与种群分组的作用, 在本次实验中, 本文确定 $K=10$ 。

人为分组是结合了文献[3,7]初始化种群方法, 将种群等分为 5 个子种群, 子种群个体数固定为 20。根据图 4 可以看到虽然 2 种算法最终都能找到全局最优, 且找到的结果一致, 但是本文中提出的高斯拟合后的单调区间分组算法比人为分组方法更早的找到全局最优, 说明本文提出的分组策略提高了算法的收敛速度。

图 5 是对算法是否增加反向算子的实验对比, 可以看出 2 种算法的结果差异非常明显, 增加反向算子后的算法寻优结果非常好, 若不设置反向算子, 子种群中存在一些粒子跳出区间范围, 会影响粒子间的信息交互。

表 2 基于拟合阈值 K 的函数 F_2 和 F_5 的平均结果
Tab.2 Average results of functions F_2 and F_5 based on the fitting threshold value K

函数	Algorithm	Mean	Std	Best
F_2	SaDCPG+PSO ($K=0$)	5.061 0e-05	2.205 9e-04	9.688 0e-11
	SaDCPG+PSO ($K=10$)	0.005 0	0.021 9	1.504 7e-08
	SaDCPG+PSO ($K=20$)	0.009 3	0.037 9	1.371 0e-08
F_5	SaDCPG+PSO ($K=0$)			
	SaDCPG+PSO ($K=10$)	8.881 8e-16	0	8.881 8e-16
	SaDCPG+PSO ($K=20$)			

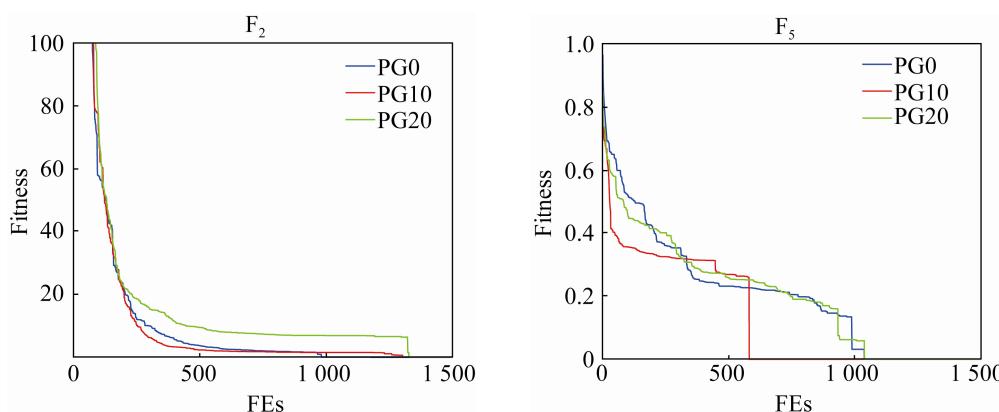


图 3 基于拟合阈值 K 取 0、10、20 的优化函数 F_2 和 F_5 的收敛图
Fig. 3 Convergence graph for functions F_2 and F_5 based on fitting threshold K of 0, 10, 20

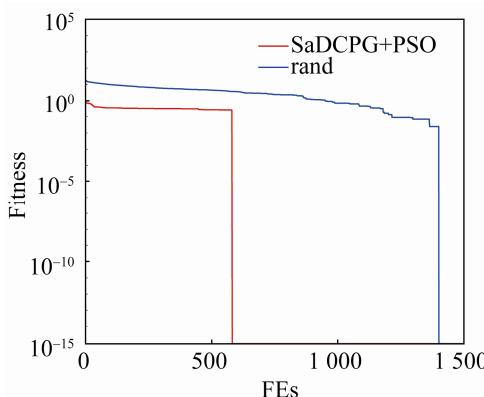


图 4 函数 F_5 随机分组与高斯拟合分组收敛图
Fig. 4 Convergence graph of artificial grouping and gaussian fitting of function F_5

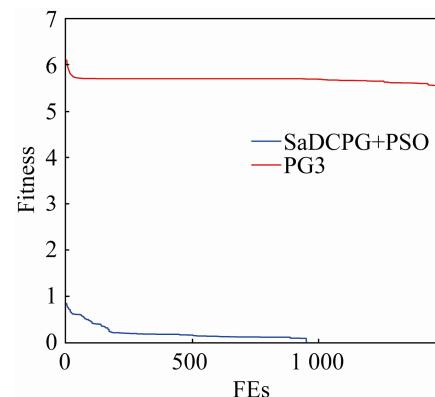


图 5 函数 F_5 有无反向算子的收敛图
Fig. 5 Convergence graph of function F_5 with or without inverse operator

2.3 与其他改进 PSO 对比实验结果分析

MSMPSO 在划分子种群的基础上通过周期性判定子种群的性能，从而指导粒子迁移，使得算法具备较好的鲁棒性。将本文提出的算法运用到粒子群算法中，并与 MSMPSO^[7]进行对比，验证种群分组自适应动态控制策略的有效性、鲁棒性。每种算法均独立运行 20 次。表 3 给出了 2 种对比算法的平均结果。MSMPSO 中与 SaDCPG+PSO 共同的参数以本文的设置为主，其余参数不变。

从表 3 中可以看出，SaDCPG+PSO 对函数 F_1 、 F_4 、 F_6 、 F_7 、 F_{11} 、 F_{12} 都可以找到全局最优解，其余函数在相同的适应度计算次数条件下，除 F_8 、 F_{10} 外，SaDCPG+PSO 的求解精度都优于 MSMPSO，尤其是函数 F_2 、 F_4 、 F_5 、 F_6 ，精度有显著提高，算法的鲁棒性更强，这是由于 MSMPSO 周期性指导个体迁移，而 SaDCPG+PSO 在每一次迭代后都会判定个体是否越界，从而更精确的指导个体运动。

表 3 各算法实验对比结果
Tab. 3 Experimental results of each algorithm

Algorithm	SaDCPG+PSO			MSMPSO		
	Mean	Std	Best	Mean	Std	Best
F_1	0	0	0	1.634 4	2.216 5	3.913 9e-06
F_2	0.005 0	0.021 9	1.504 7e-08	48.893 0	36.751 7	17.891 7
F_3	0.683 7	0.072 6	0.666 7	1.615 5	1.602 8	0.669 8
F_4	3.571 8e-27	1.071 5e-26	0	1.036 4e-11	3.409 7e-11	4.376 9e-24
F_5	8.881 8e-16	0	8.881 8e-16	4.021 4	2.095 8	1.020 9e-06
F_6	0.750 6	2.951 2	0	24.666 9	5.118 5	16.109 3
F_7	0	0	0	0.582 3	0.354 1	0.004 2
F_8	0.006 4	0.027 2	4.123 0e-07	0.088 0	0.079 8	7.664 6e-08
F_9	0.341 7	1.078 2	3.057 6e-04	0.561 7	0.401 2	0.021 0
F_{10}	1.383 8e+03	864.101 4	947.507 1	5.119 0e+03	748.230 0	3.395 6e+03
F_{11}	0.020 8	0.090 6	0	0.858 0	0.899 2	0.026 7
F_{12}	0	0	0	0.558 4	0.640 8	7.786 0e-06

图 6 的收敛图更直观地比较了 SaDCPG+PSO 和 MSMPSO, 横轴是适应度计算次数, 纵轴是平均适应度值。从图中可以看出, SaDCPG+PSO 和 MSMPSO 两算法的收敛速度和精度对比明显, 本

文算法的效果更佳; 对于函数 F_1 、 F_7 、 F_{12} , SaDCPG+PSO 在未完成全部迭代次数时就能优先找到全局最优值。

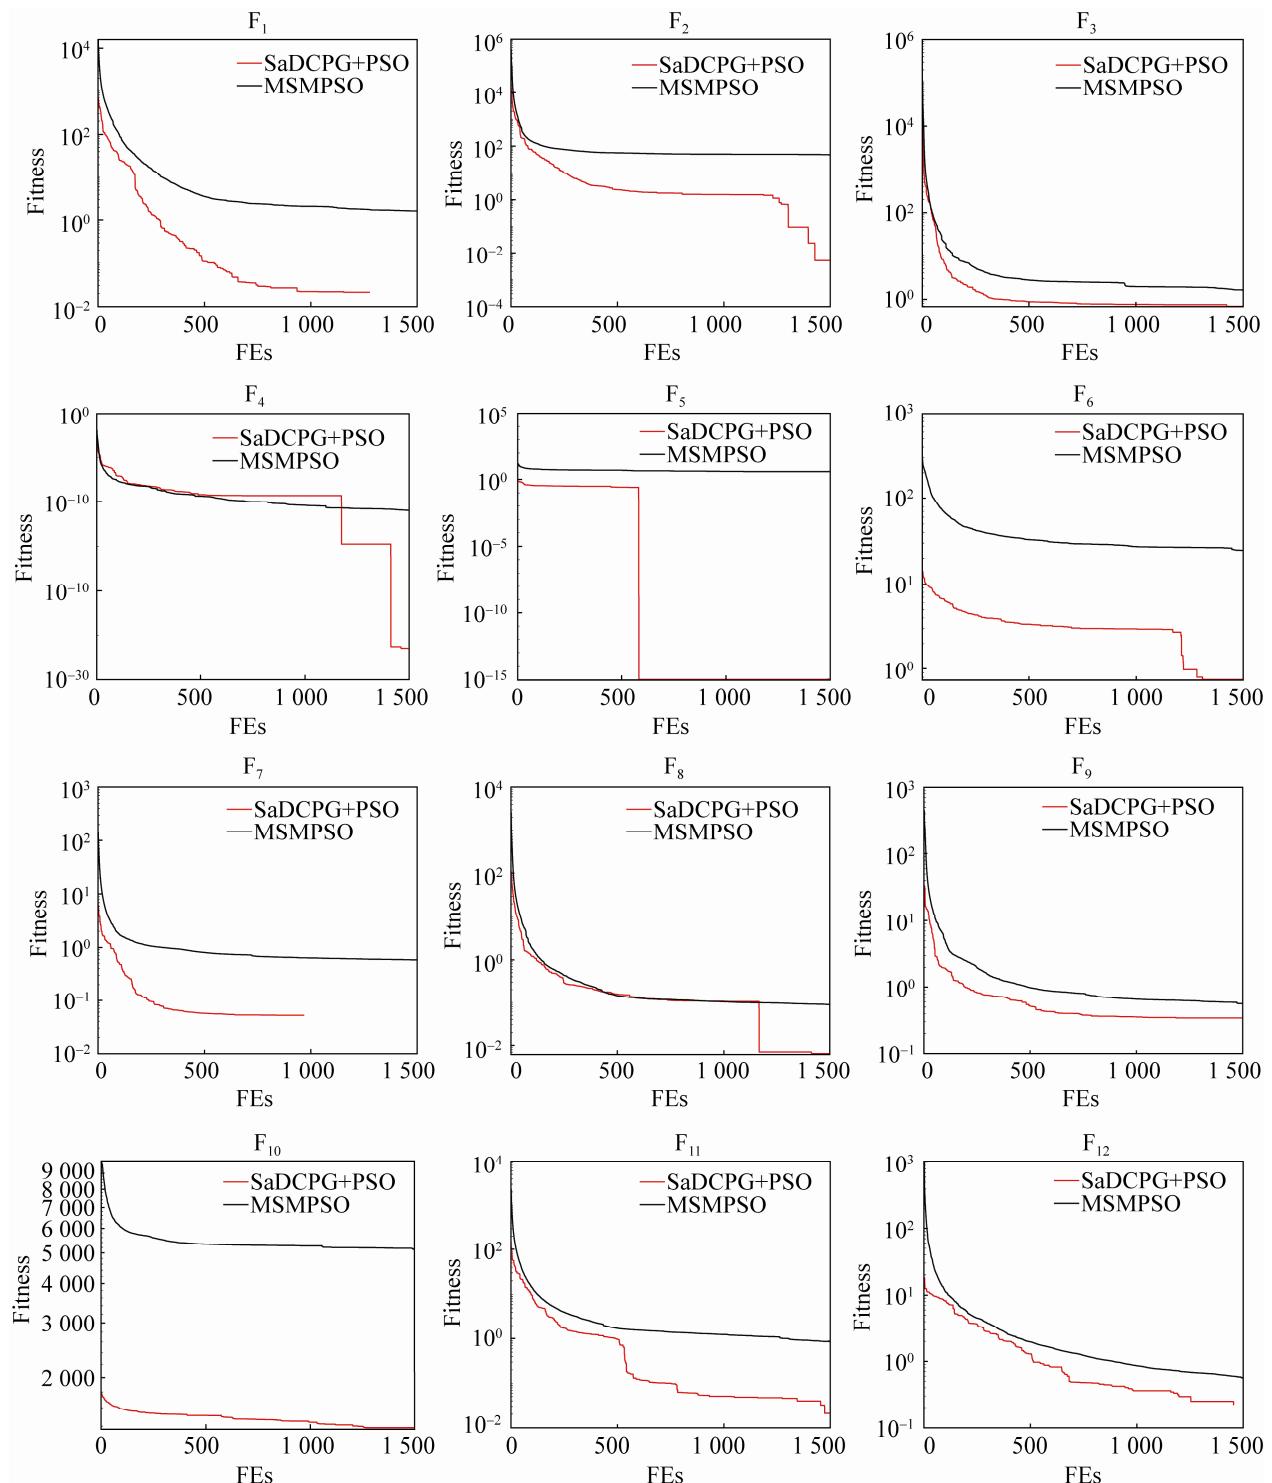


图 6 SaDCPG+PSO 和 MSMPSO 优化函数 $F_1 \sim F_{12}$ 的收敛图
Fig. 6 Convergence graph of SaDCPG+PSO and MSMPSO for functions $F_1 \sim F_{12}$

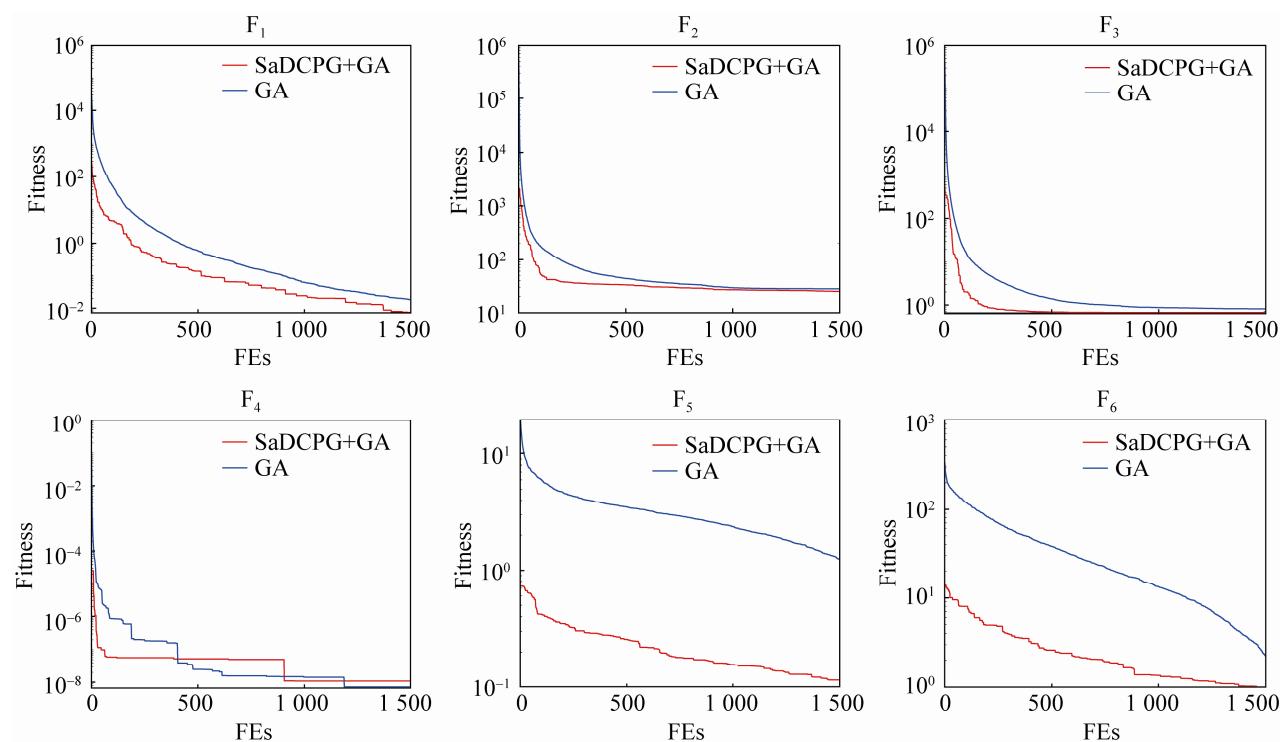
为进一步验证 SaDCPG 的性能及普适性, 我们还将此策略运用于遗传算法, 将标准遗传算法与其对比, 表 4 给出了 GA 和 SaDCPG+GA 的平均比较结果。

分析表 4 的实验结果可知, 在适应度计算相同的情况下, 除了函数 F₄ 和 F₁₂, SaDCPG+GA 在其它函数上的平均寻优结果均优于 GA, 尤其是函数

F₁、F₆、F₇、F₉、F₁₁ 的收敛精度都有较大提高, 其余函数也有略微的改善。图 7 中 SaDCPG+GA 在多峰函数上的收敛速度和精度优势更明显, 由于前期高斯拟合曲线的作用, 两算法在同等时间内 SaDCPG+GA 能找到更优的解, 再次说明高斯拟合曲线分组对提高算法精度的有效性。

表 4 GA 和 SaDCPG+GA 优化函数 F₁~F₁₂ 的结果
Tab. 4 Results of GA and SaDCPG+GA for functions F₁~F₁₂

Algorithm	GA			SaDCPG+GA		
	Mean	Std	Best	Mean	Std	Best
F ₁	0.018 5	0.007 4	0.008 1	0.007 5	0.022 4	1.789 3e-05
F ₂	27.800 4	1.015 8	24.039 3	24.898 8	32.256 4	3.449 7
F ₃	0.809 4	0.521 6	0.668 4	0.667 1	0.001 7	0.666 7
F ₄	7.086 9e-09	1.543 8e-08	1.187 1e-14	1.079 6e-08	3.083 6e-08	7.374 7e-13
F ₅	1.251 5	0.801 8	0.059 7	0.114 9	0.442 0	0.001 3
F ₆	2.249 3	3.456 7	0.033 2	0.990 7	3.796 8	4.378 5e-04
F ₇	0.076 2	0.046 4	0.031 9	0.022 5	0.069 4	2.212 3e-04
F ₈	0.036 1	0.012 1	0.014 2	0.010 1	0.017 2	0.001 7
F ₉	0.001 5	4.936 1e-04	5.747 6e-04	2.494 5e-04	8.683 4e-04	7.478 3e-07
F ₁₀	3.377 9e+033	435.334 1	2.489 4e+03	595.107 6	980.140 0	1.470 0
F ₁₁	0.003 2	0.001 8	0.001 2	0.001 9	0.007 4	2.532 7e-05
F ₁₂	2.325 2	0.725 3	1.232 8	3.118 7	5.274 0	0.327 9



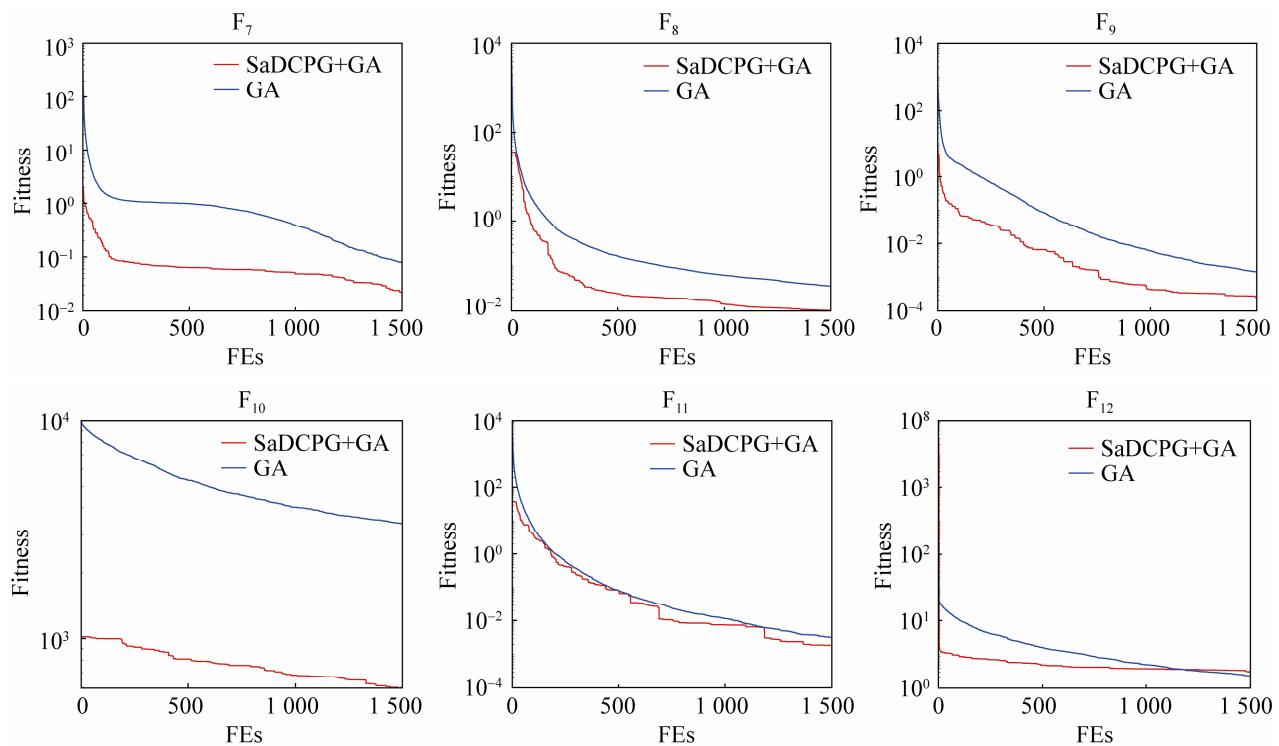


图7 各GA和SaDCPG+GA优化函数 $F_1\sim F_{12}$ 的收敛图
Fig. 7 Convergence graph of GA and SaDCPG+GA for functions $F_1\sim F_{12}$

3 结论

种群分组在自然计算方法中本质上都是随机的,子种群中确定粒子数的方法也大多是人为固定的。本文中通过高斯拟合以及函数单调空间划分子种群,在拟合前种群先进行一定次数迭代,使得拟合曲线趋于目标函数曲线,进而子种群划分会更加精确;子种群并行优化过程中对有越界趋势的个体采用逆向策略,加快收敛速度。但是,本策略的不足之处在于一些高维函数拟合分组后容易陷入局部最优;算法时间复杂度较高;拟合函数的选取及拟合曲线的平滑度取值影响分组的精确度。结合实验可以看出算法寻优结果与函数维数有很大的联系,在后续研究中,可以将SaDCPG从高维函数角度和以上欠缺的方面进行深入的改进,使得算法精度和收敛速度得到更进一步提高和改善,降低时间复杂度。

参考文献:

[1] 王蓉芳, 焦李成, 刘芳, 等. 自适应动态控制种群规模

的自然计算方法[J]. 软件学报, 2012, 23(7): 1760-1772.

Wang Rongfang, Jiao Licheng, Liu Fang, et al. Nature Computation with Self-Adaptive Dynamic Control Strategy of Population Size[J]. Journal of Software, 2012, 23(7): 1760-1772.

[2] 康琦, 安静, 汪镭, 等. 自然计算的研究综述[J]. 电子学报, 2012, 40(3): 548-558.

Kang Qi, An Jing, Wang Lei, et al. Nature-Inspired Computation: A Survey[J]. Acta Electronica Sinica, 2012, 40(3): 548-558.

[3] 吴浩扬, 常炳国, 朱长纯, 等. 基于模拟退火机制的多种群并行遗传算法[J]. 软件学报, 2000, 11(3): 416-420.
Wu Haoyang, Chang Bingguo, Zhu Changchun, et al. A Multigroup Parallel Genetic Algorithm Based on Simulated Annealing Method[J]. Journal of Software, 2000, 11(3): 416-420.

[4] 郭观七, 喻寿益, 贺素良. 自适应小生态遗传算法的理论分析和加速技术[J]. 计算机学报, 2003, 26(6): 753-758.

Guo Guanqi, Yu Shouyi, He Suliang. Theoretic analysis and accelerating of a class of self-adaptive niching genetic algorithms[J]. Chinese Journal of Computers, 2003, 26(6): 753-758.

[5] 周丹, 谢敏, 刘方, 等. 基于精英协同的多种群分布估计算法[J]. 计算机应用与软件, 2017, 34(1): 281-285.

- Zhou Dan, Xie Min, Liu Fang, et al. Multi-population estimation of distribution algorithm based on elite cooperation[J]. Computer Applications and Software, 2017, 34(1): 281-285.
- [6] 邓先礼, 魏波, 曾辉, 等. 基于多种群的自适应迁移 PSO 算法[J]. 电子学报, 2018, 46(8): 1858-1865.
- Deng Xianli, Wei Bo, Zeng Hui, et al. Multi-population based self-adaptive migration PSO[J]. Acta Electronica Sinica, 2018, 46(8): 1858-1865.
- [7] 杜永兆, 范宇凌, 柳培忠, 等. 多种群协方差学习差分进化算法[J]. 电子与信息学报, 2019, 41(6): 1488-1495.
- Du Yongzhao, Fan Yuling, Liu Peizhong, et al. Multi-populations covariance learning differential evolution algorithm[J]. Journal of Electronics and Information Technology, 2019, 41(6): 1488-1495.
- [8] Clerc M, Kennedy J. The particle swarm-explosion, stability, and convergence in a multidimensional complex space[J]. IEEE Transactions on Evolutionary Computation (S1089-778X), 2002, 6(1): 58-73.
- [9] J Kennedy. Bare bones particle swarms [C]. Proceedings of the 2003 IEEE Swarm Intelligence Symposium. NJ: IEEE, 2003: 80-87.
- [10] 王东风, 孟丽, 赵文杰. 基于自适应搜索中心的骨干粒子群算法[J]. 计算机学报, 2016, 39(12): 2652-2667.
- Wang Dongfeng, Meng Li, Zhao Wenjie. Improved bare bones particle swarm optimization with Adaptive search center[J]. Chinese Journal of Computers, 2016, 39(12): 2652-2667.
- [11] Wang L, He L, Mishra A, Li C M. Active contours driven by local Gaussian distribution fitting energy[J]. Signal Processing (S0165-1684), 2009, 89(12): 2435-2447.
- [12] 高雅, 周佳霖, 侯雪, 等. 基于高斯拟合的高光谱影像配准算法[J]. 红外与激光工程, 2016, 45(增2): 131-136.
- Gao Ya, Zhou Jialin, Hou Xue, et al. Registration algorithm for hyperspectral image based on Gaussian fitting[J]. Infrared and Laser Engineering, 2016, 45(S2): 131-136.
- [13] 陈海鹏, 申铉京, 龙建武. 采用高斯拟合的全局阈值算法阈值优化框架[J]. 计算机研究与发展, 2016, 53(4): 892-903.
- Chen Haipeng, Shen Xuanjing, Long Jianwu. Threshold optimization framework of global thresholding algorithms using gaussian fitting[J]. Journal of Computer Research and Development, 2016, 53(4): 892-903.
- [14] Cheng Song, Yuyao He, Branko Ristic, et al. Collaborative info taxis: Searching for a signal-emitting source based on particle filter and Gaussian fitting[J]. Robotics and Autonomous Systems (S0921-8890), 2020, 125(C):1-11.
- [15] 周新宇, 吴志健, 王晖, 等. 一种精英反向学习的粒子群优化算法[J]. 电子学报, 2013, 41(8): 1647-1652.
- Zhou Xinyu, Wu Zhijian, Wang Hui, et al. Elite opposition-based particle swarm optimization[J]. Acta Electronica Sinica, 2013, 41(8): 1647-1652.
- [16] 罗强, 季伟东, 徐浩天, 等. 一种最优粒子逐维变异的粒子群优化算法[J]. 小型微型计算机系统, 2020, 41(2): 259-263.
- Luo Qiang, Ji Weidong, Xu Haotian, et al. Particle swarm optimization with global best particle dimension-by-dimension mutation[J]. Journal of Chinese Computer Systems, 2020, 41(2): 259-263.
- [17] Shi Y, Eberhart R C. A modified particle swarm optimizer[C]. Proceedings of the IEEE International Conference on Evolutionary Computation. Piscataway, NJ, Anchorage, AK USA: IEEE service center, 1998: 69-73.
- [18] Holland J H. Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence[D]. Michigan, USA: University of Michigan Press, 1975.