

独立局部搜索与多区域渐近收敛的新型PSO算法

王玉昆^{1,2}, 陈雪波^{2†}

(1. 辽宁科技大学 化学工程学院, 辽宁 鞍山 114051;

2. 辽宁科技大学 电子与信息工程学院, 辽宁 鞍山 114051)

摘要: 针对标准粒子群算法(PSO)全局与局部搜索能力相互制约的缺点, 提出一种带有独立局部搜索机制、多区域搜索策略和渐近收敛能力的新型PSO算法(ILS-PSO). 设计新的简化参数的全局搜索公式、非劣解邻域局部搜索公式和当前最优解邻域深度搜索公式, 使算法具备独立的全局与局部搜索能力. 通过参数 ξ 和 λ 协调算法的全局与局部搜索能力, 以实现算法的多区域搜索和渐近式收敛. 典型函数及其偏移函数的对比测试结果表明, ILS-PSO算法具有良好的优化性能, 其综合性能优于其他对比算法.

关键词: 独立局部搜索; 非劣解; 单维扰动方式; 变步长; 渐近式收敛

中图分类号: TP301.6

文献标志码: A

Improved multi-area search and asymptotic convergence PSO algorithm with independent local search mechanism

WANG Yu-kun^{1,2}, CHEN Xue-bo^{2†}

(1. School of Chemical Engineering, University of Science and Technology Liaoning, Anshan 114051, China; 2. School of Electronic and Information Engineering, University of Science and Technology Liaoning, Anshan 114051, China)

Abstract: Global and local search abilities restrict each other in the standard particle swarm optimization(PSO) algorithm. A new improved PSO algorithm with the independent local search(PSO-ILS) mechanism, multi-area search strategy and asymptotic convergence ability is proposed. Firstly, a new global search formula with simplified parameters, a local one for neighborhood of non-inferior solutions and a depth one for neighborhood of current optimal solution, are designed. Therefore, the proposed algorithm possesses independent both global and local search abilities. Then, for realizing the multi-area search strategy and asymptotic convergence abilities, the parameters ξ and λ are defined to coordinate the abilities of both global and local searches. The comparative experimental result of typical and their shifted functions demonstrates that the PSO-ILS algorithm is of better performance than other algorithms.

Keywords: independent local search; non-inferior solution; unidimensional disturbance mode; variable step size; asymptotic convergence

0 引言

标准粒子群算法(PSO)具有参数少、结构简单、易于实现的优点, 目前广泛应用于生产调度、控制器参数整定、神经网络结构优化、分子团簇设计等众多工程应用和科学研究领域. 与其他群智能算法类似, 对于高维、多峰函数优化问题, PSO算法也存在着易早熟、收敛速度慢和寻优精度差的缺点^[1-3]. 实际上, 搜索后期种群多样性丧失是PSO算法最大的缺点^[4]. 目前, 针对PSO算法的改进主要集中在维护种

群多样性、提高搜索能力、收敛速度或精度上, 改进方法主要有以下3类:

1) 改进算法结构或参数调整方法. 文献[1]通过改进权重 ω 的调整策略避免算法陷入局部最优; 文献[2]将混沌思想引入PSO算法, 通过对粒子速度和位置的混沌扰动提高算法的搜索能力; 文献[3]提出了一种层次学习骨干粒子群优化算法, 采用跳跃策略增强粒子的逃逸能力, 采用扰动策略提高解的质量; 文献[5]提出了一种增强引导型PSO算法, 通过五

收稿日期: 2017-05-02; 修回日期: 2017-09-13.

基金项目: 国家自然科学基金项目(71571091, 61473054).

责任编委: 巩敦卫.

作者简介: 王玉昆(1982—), 男, 讲师, 博士生, 从事群智能算法及化工优化的研究; 陈雪波(1960—), 男, 教授, 博士生导师, 从事群集智能、复杂系统分析与建模等研究.

†通讯作者. E-mail: xuebochen@126.com

阶段连续变异策略引导算法跳出局部最优; 文献[6]研究了一种代理辅助协作模式的PSO算法, 提高了算法的求解质量。

2) 引入多种群搜索策略. 文献[7]研究了一种多种群SMPSO算法, 算法在逃逸能力、收敛速度和求解精度上都有所提高; 文献[8]提出了一种小生境粒子群算法, 通过多子群搜索提高了算法的全局优化能力; 文献[9]提出了一种基于随机评价机制的交互式双子群QPSO算法, 通过子群间的信息交互提高了算法的求解精度。

3) 与其他优化算法结合. 文献[10]研究了PSO与GA算法的混合算法, 通过遗传算法的交叉和变异策略平衡PSO算法的全局搜索和局部开发能力; 文献[11]提出了一种粒子群与人工蜂群的混合优化算法, 并应用在神经网络优化中; 文献[12]提出了一种CBO-PSO混合优化算法, 提高了算法的搜索精度; 文献[13]提出了一种内嵌微遗传算法的PSO变种(MGA嵌入算法), 提高了算法的性能; 文献[14]提出了一种Nelder-Mead-模糊自适应混合粒子群算法, 更好地解决了多线路拥塞管理优化问题; 文献[15]提出了一种基于马尔科夫链模型的混合粒子群算法, 提高了算法的收敛速度。

上述改进在一定程度上提升了PSO算法的性能, 但都没有从本质上消除标准PSO算法全局搜索能力和局部搜索能力相互制约的缺点, 从而限制了算法性能的大幅提升. 由文献[7-9]可知, 多种群搜索可实现对多个可能最优区域进行有效搜索, 避免算法陷入局部最优. 但多种群算法中, 子群划分方式及规模、子群间的信息交互方式都影响算法的性能, 算法的实现相对复杂^[16-17].

本文融合粒子群算法改进的主要思想, 从改变算法的结构、维护种群的多样性和融合其他群智能算法3个方面入手对标准PSO算法进行改进, 提出一种带有独立局部搜索机制、多区域搜索和渐近式收敛的ILS-PSO算法. 算法通过简化参数的全局搜索公式实现全局搜索任务; 通过对非劣解邻域的局部搜索实现对多个可能最优区域的有效发掘; 通过借鉴人工蜂群算法扰动机制的当前最优解邻域的深度搜索公式, 提高算法的收敛速度和精度; 同时算法通过协调参数使算法从全局搜索向局部搜索转变, 从多区域搜索向最优解深度搜索转变, 从而实现算法的渐近式收敛. 所提出的ILS-PSO算法在避免大幅增加算法复杂度的基础上, 为克服标准PSO算法的缺陷提供了一种新的解决思路。

1 标准PSO算法及缺陷分析

1.1 标准PSO算法

标准PSO算法通过粒子的速度更新实现位置更新, 对于求解变量为 $X = \{x_1, x_2, \dots, x_D\}$, 目标函数为 $\min(f(X))$ 的优化问题, 标准PSO算法的粒子更新公式为

$$\begin{cases} v_{id}(t+1) = \omega v_{id}(t) + c_1 r_1 (pb_{id}(t) - x_{id}(t)) + \\ \quad c_2 r_2 (gb_d(t) - x_{id}(t)), \\ x_{id}(t+1) = x_{id}(t) + v_{id}(t). \end{cases} \quad (1)$$

其中: r_1 和 r_2 为 $[0, 1]$ 之间均匀分布的随机数, c_1 和 c_2 为学习因子, ω 为惯性权重, $v_{id}(t)$ 和 $x_{id}(t)$ 分别为第 t 次迭代时第 i 个粒子的第 d 维变量的速度和位置, $pb_i(t)$ 为当前每个粒子所经历的最优解, $gb_i(t)$ 为算法当前搜索到的最优解。

标准PSO算法通过权重 ω 协调算法的局部搜索能力和全局搜索能力, ω 的调整公式一般为

$$\omega = \omega_{\max} - \frac{\omega_{\max} - \omega_{\min}}{T} t. \quad (2)$$

其中: t 为当前迭代次数, T 为算法的最大迭代次数^[5-9].

1.2 标准PSO算法缺陷分析

对于标准PSO算法的缺陷, 通过一个典型欺骗函数(Schwefel)的优化过程进行说明. 该函数的表达式为

$$f(x) = 418.9829 \times D - \sum_{i=1}^D x_i \sin(|x_i|^{1/2}).$$

其中: D 为函数的维数, $x_i \in [-500, 500]$. 全局最小值近似为0, 在 $x_i = 418.9829$ 处取得。

算法测试时, $c_1 = c_2 = 2$, 粒子移动速度范围 $v_i \in [-500, 500]$, $\omega \in [0.3, 1]$, ω 的值通过式(2)进行调整, 粒子规模为30, 迭代次数为500. 算法执行后, 仿真效果如图1所示。

由图1(a)可见, PSO算法的粒子基本集中在搜索空间的左上角, 对于其他可能存在最优解的区域, 算法不能进行有效的搜索. 由图1(b)可见, 随着迭代次数的增加, 粒子聚集到 $x_1 = -300$ 附近后便陷入了局部最优. 算法后期由于 ω 变小使其局部搜索能力很强, 但全局搜索能力极差。

为了考察标准PSO算法对不同维数函数的适应能力, 图2给出了函数维数分别为2~10时, 算法独立运行30次寻优结果的箱线统计图。

由图2可见: 当函数维数为2时, 搜索结果的中位值接近全局最优值, 算法能够以较大概率收敛; 当维

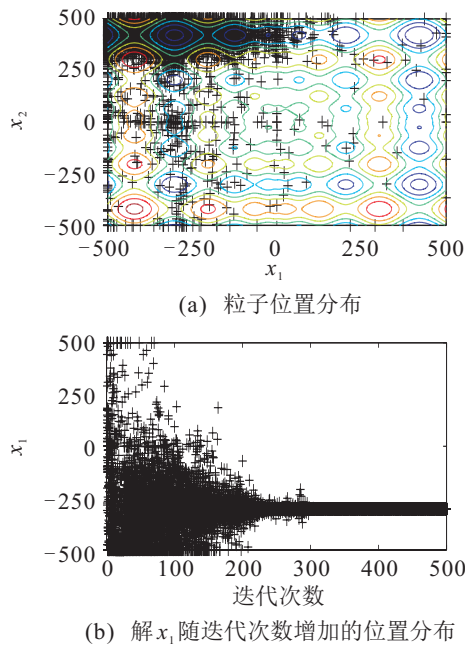


图1 标准PSO算法仿真效果




图2 PSO算法寻优结果箱线图

数大于4时,算法已经很难收敛,且维数越高,搜索到的结果越差.这表明,标准PSO算法对于复杂函数的搜索能力很差,且随着维数的增加,算法的性能显著变差.产生上述缺陷的主要原因为:

1) 标准PSO算法没有独立的全局和局部搜索公式,全局搜索能力和局部搜索能力相互制约,无法各自发挥更好的作用.

2) 标准PSO算法没有对非劣解邻域的局部搜索能力,容易陷入某个局部极小点,从而无法对其他可能的全局最优区域进行有效的搜索.

3) 搜索后期算法的全局搜索能力丧失,一旦陷入局部极小,便失去了搜索能力.

本文将主要围绕标准PSO算法的上述缺陷进行改进,设计新的ILS-PSO算法.

2 改进的ILS-PSO算法

2.1 算法的总体改进思想

由前面分析可知,要克服标准PSO算法全局和局部搜索能力相互制约的缺陷,必须设计独立的全局和局部搜索公式.全局搜索是在整个搜索空间内进行粗略的搜索,局部搜索是对当前最优解的邻域进行

深度搜索^[17].若采用单一的局部搜索方式,一旦出现图3所示的情况,则算法极易陷入局部最优.对于图3所示求解极小值的情况,局部搜索行为容易使适应度差的粒子聚集到A附近对A的邻域进行搜索.此时便会错过对适应度与其相近的B和F的邻域进行搜索的机会,算法容易在A处陷入局部最优(这种行为与社会群体中不安全行为的涌现,如踩踏事件的生成非常相似,极易造成灾难性后果^[18]).




图3 粒子移动示意图

若能对适应度与当前最优适应度相近的粒子的邻域(可能的最优区域)进行局部搜索,则算法搜索到更好值的概率便会大大增加.因此本文定义了两种局部搜索行为,即:当前最优解邻域的深度搜索行为(提高搜索精度)和非劣解邻域的局部搜索行为(避免陷入局部最优).这里非劣解邻域局部搜索的思想为:当种群中某些粒子搜索到的最优适应度与群体当前最优适应度差别很小时,认为该粒子搜索到的解为非劣解,其邻域内可能存在更好的解,这些个体将不再朝着最优解的方向移动,而是在自己的周围搜索可能存在的更好解.

全局搜索行为和非劣解邻域局部搜索行为虽然可以避免算法陷入局部最优,但如果搜索后期强度太大,则必然会降低对当前最优解邻域搜索的强度,从而降低算法的收敛精度,因此需要对算法的全局搜索能力、非劣解邻域的局部搜索能力和当前最优解邻域的深度搜索能力进行协调,使粒子逐步向当前最优解收敛,从而形成一种具有独立局部搜索机制、多区域搜索和渐近式收敛的新型PSO算法.

2.2 独立的全局搜索公式

为了避免算法陷入局部最优,使算法在搜索的全程都具备全局搜索能力,设计新的独立全局搜索公式

$$\begin{cases} v_{id}(t+1) = \\ v_{id}(t) + c\varepsilon(x_{id}(t) - r_1pb_{id}(t) - r_2gb_d(t)), \\ x_{id}(t+1) = x_{id}(t) + v_{id}(t). \end{cases} \quad (3)$$

其中: c 为学习因子, ε 为 $[0, 1]$ 之间均匀分布的随机数,其他参数的含义与式(1)一致.相对于标准PSO算法,这里只有一个学习因子 c ,减少了需要调整的参数,并消了权重系数 ω ,使算法具备独立的全局搜索

能力.

2.3 非劣解的判定与其邻域的局部搜索公式

为了实现对非劣解邻域的局部搜索, 首先设计非劣解判定条件

$$Fb_i(t) - F_{\text{best}}(t) < \lambda[\bar{F}b(t) - F_{\text{best}}(t)]. \quad (4)$$

其中: λ 为协调参数, $Fb_i(t)$ 、 $F_{\text{best}}(t)$ 和 $\bar{F}b(t)$ 分别为第 t 次迭代时粒子 i 所记录的最好适应度、算法当前搜索到的最优适应度和各粒子搜索到的最优适应度的平均值. 若式(4)的条件成立, 则所对应粒子的坐标判定为非劣解, 在 $t+1$ 次迭代时, 算法对该粒子按下式所示的非劣解邻域局部搜索公式进行移动:

$$x_i(t+1) = \text{pbest}_i(t) + \eta \frac{X_{\text{max}} - X_{\text{min}}}{\gamma} \exp\left(\frac{t}{T}\right). \quad (5)$$

其中: η 为 D 维 (D 为解的维数) $[-1, 1]$ 之间的随机数, $x_i(t+1)$ 为第 $t+1$ 次迭代第 i 个粒子的位置, $\text{pbest}_i(t)$ 为第 t 次迭代粒子 i 所记录的最好位置, X_{max} 和 X_{min} 分别为搜索空间的上下界, T 为最大迭代次数, t 为当前迭代次数. t 和参数 γ 的值越大, 非劣解邻域的搜索范围越小, 搜索的精细程度越高. γ 的值一般取为 20 即可.

2.4 当前最优解邻域的深度搜索公式

全局搜索和非劣解邻域的局部搜索虽然可以避免算法陷入局部最优, 但会降低算法的收敛精度, 因此有必要对当前最优解的邻域进行深度搜索. 为了提高深度搜索效率和细致程度, 这里借鉴人工蜂群算法^[19]的扰动方式, 设计基于单维扰动机制和变步长搜索策略的当前最优解邻域深度搜索公式

$$\begin{aligned} j &= \text{fix}(D \times \mu) + 1; \\ \Phi &= \{\Phi_1, \Phi_2, \dots, \Phi_D\}, \Phi_k = \begin{cases} 0, & k \neq j; \\ 1, & k = j; \end{cases} \\ S &= \left(\frac{T - \chi t}{T}\right)^c \exp(-t/T); \\ x_i(t+1) &= \text{gb}(t) + c\Phi\left(\frac{1}{2} - \theta\right)S. \end{aligned} \quad (6)$$

其中: D 为解的维数, μ 和 θ 分别为 $[0, 1]$ 之间均匀分布的随机数, $\text{fix}(\cdot)$ 为截尾取整, j 为 $[1, D]$ 之间的随机整数, $k = (1, 2, \dots, D)$, c 为学习因子, $\text{gb}(t)$ 为当前最优解, S 为搜索步长, 可调系数 χ 可以调节深度搜索的最小步长.

由式(6)可见, 对当前最优解邻域进行深度搜索时, 采用对当前最优解的某一维进行随机扰动的方式产生新解, 相对于全扰动方式, 对当前最优解邻域的搜索会更加细致, 搜索效率也会更高(例如排队时,

队伍中只有一个人位置不对, 如果此时对所有人的位置都进行随机调整, 即全扰动, 则可能会花费较长时间. 若采用单维扰动, 只调整某个人的位置, 一旦随机选择到位置不对的那个人, 则很快便可以队伍排好). 变步长搜索策略的引入会使搜索的步长随迭代次数的增加而减小, 算法对最优解邻域搜索的精细程度会逐渐提高, 有利于提高搜索的精度.

2.5 全局与局部搜索能力的协调

前文定义了 ILS-PSO 算法的 3 种搜索行为, 与全局搜索行为不同, 非劣解邻域的局部搜索行为和最优解邻域的深度搜索行为均属于局部搜索行为. 为了协调算法的全局搜索与局部搜索能力, 定义协调参数

$$\xi = \exp(-t/T). \quad (7)$$

其中: T 为最大迭代次数, t 为当前迭代次数.

ILS-PSO 算法进行全局搜索与局部搜索的控制方式为: 对于每一个粒子, 若对于 $[0, 1]$ 之间的随机数 β , 满足 $\beta < \xi$, 则该粒子进行全局搜索, 否则进行局部搜索. 在整个搜索过程中, ξ 的值从 1 ~ 0.3679 非线性递减, 算法能够以一定的概率进行独立的全局搜索和局部搜索, 且局部搜索能力会随着迭代次数的增加而增强.

2.6 非劣解与最优解邻域搜索能力的协调

对非劣解邻域进行搜索是为了发掘非劣解周围可能存在的更好解, 避免算法陷入局部最优, 但选取的非劣解数量过多, 会降低当前最优解邻域深度搜索的强度, 导致算法收敛精度下降. 由式(4)可见, 协调参数 λ 可以调整非劣解的数量, 这里将参数定义为

$$\lambda = \log_{0.5}(-t/T). \quad (8)$$

其中: T 为最大迭代次数, t 为当前迭代次数. λ 的值会随着迭代次数的增加而减小, 从而减少非劣解的数量, 降低对非劣解邻域的搜索强度, 算法进而从非劣解邻域的搜索逐步转向当前最优解邻域的深度搜索, 这样可以避免算法前期陷入局部最优, 并提高算法后期的收敛精度.

3 多区域渐近式收敛方式的实现与分析

3.1 多区域渐近式收敛方式的实现

算法总体实现流程如下.

Step 1: 初始化粒子规模 M , 最大迭代次数 T , 搜索空间范围 $[X_{\text{min}}, X_{\text{max}}]$, 粒子运动速度范围 $[V_{\text{min}}, V_{\text{max}}]$, 学习因子 c 和可调系数 χ , 随机产生各粒子的位置和速度, 计算每个粒子的适应度, 记录当前最优的适应度和当前最优解, 并记录每个粒子的最优位置. 令迭代次数 $t = 1$.

Step2: 判断是否满足搜索终止条件,若满足,则输出最优适应度和最优解,否则继续搜索.

Step3: 迭代搜索. 对于每一个粒子,判断是否满足全局搜索条件,若满足,则该粒子按照式(3)进行全局搜索,否则进行局部搜索. 判断是否满足非劣解邻域搜索条件,若满足,则该粒子按照式(5)对非劣解的邻域进行局部搜索,否则按照式(6)对当前最优解的邻域进行深度搜索,最终形成新一代种群.

Step4: 计算新一代种群中每个粒子的适应度,更新全局最优适应度和全局最优解,更新每个粒子搜索到的最优解. 令迭代次数 $t = t + 1$,返回Step2.

算法流程如图4所示.

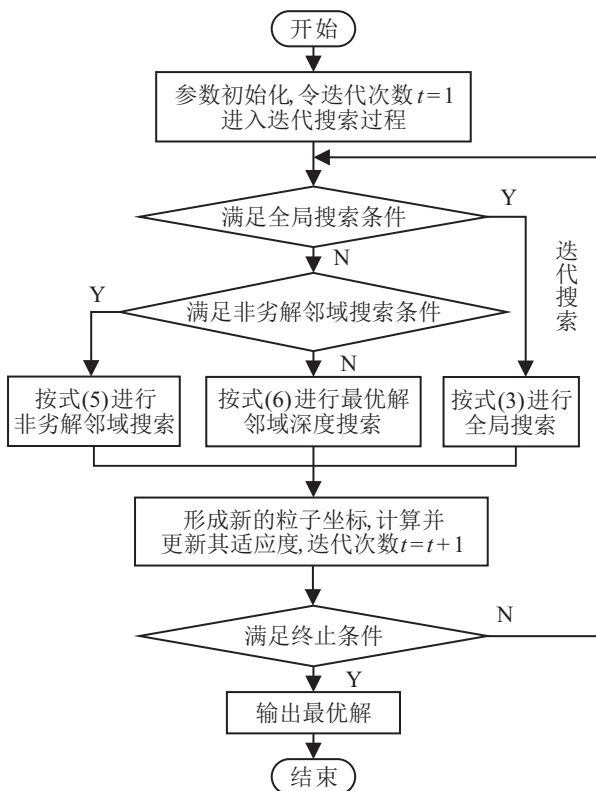


图4 算法总体实现流程

3.2 ILS-PSO算法收敛过程分析

同样通过对 Schwefel 函数的搜索过程来说明 ILS-PSO 算法收敛过程的特点和优点. 算法测试时, 学习因子 $c = 2$, 可调系数 $\chi = 0.95$, 粒子的速度范围 $[-500, 500]$. 粒子规模为 30, 迭代次数为 500. ILS-PSO 算法执行后, 仿真效果如图5所示.

由图5(a)可见, ILS-PSO 算法的种群多样性比 PSO 算法更强, 能够对多个局部最小区域进行有效搜索, 从而可以降低算法陷入局部最优的概率. 由图5(b)可见, 在整个搜索过程中, ILS-PSO 算法的粒子呈现分散和聚集两种状态, 即全局搜索和局部搜索是同时存在的, 即使在搜索的后期算法也能进行全局搜

索.

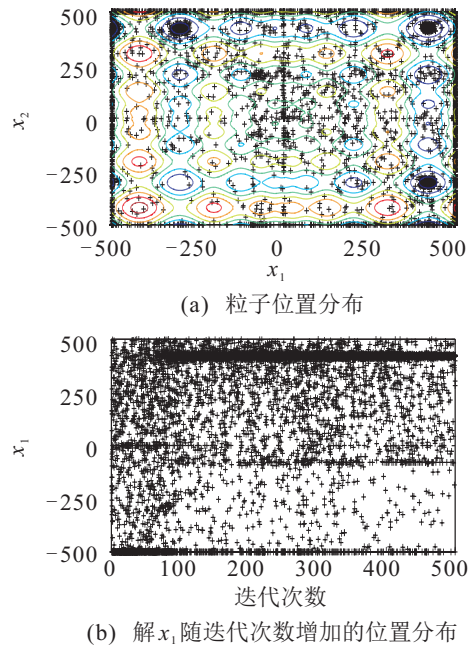


图5 ILS-PSO算法仿真效果图

图6给出了函数维数分别为2~10时, ILS-PSO 算法独立运行30次寻优结果的箱线图. 由图6可见, 对于不同维数的 Schwefel 函数, 箱线图的箱体长度趋近0, 这表明算法的稳定性很强.




图6 ILS-PSO算法寻优结果箱线图

在270个测试结果中, 搜索到的最差值小于 1.5×10^{-4} , 算法成功收敛了270次, 这表明本文所提出的 ILS-PSO 算法的收敛能力比标准 PSO 算法有了极大提高.

4 数值实验与结果分析

为验证本文所提出 ILS-PSO 算法的性能, 以及标准 PSO 算法和改进型 PSO 算法 (SA-COSO 算法^[6]、HLBPSO 算法^[3] 和 DIR-QPSO 算法^[9]) 的性能进行对比, 选取表1所示的9个典型测试函数对各算法进行对比测试, 9个测试函数包括单峰、多峰和病态函数, 有一定的代表性. 由图4可见, ILS-PSO 算法每个粒子一次迭代搜索只进行一次适应度评价, 在相同的种群规模和迭代次数下, ILS-PSO 算法与上述对比算法的比较是公平的.

表1 典型测试函数

函数	名称	类型	搜索范围	最小值
f_1	Sphere	单峰	[-100, 100]	0
f_2	DeJongF4	单峰	[-10, 10]	0
f_3	Rosenbrock	单峰病态	[-10, 10]	0
f_4	Rastrigin	多峰	[-5.12, 5.12]	0
f_5	Griewank	多峰	[-600, 600]	0
f_6	Ackley	多峰	[-32.768, 32.768]	0
f_7	Schwefel	多峰	[-500, 500]	0
f_8	Michalewicz	多峰	[0, π]	—
f_9	Penalized 2	多峰	[-50, 50]	0

算法测试时,粒子的移动速度范围与搜索范围一致,各算法的种群规模均为50,迭代次数均为1000,其他参数设置如下:

- 1) 标准PSO算法:学习因子 $c_1 = c_2 = 2$, 初始惯性权重 $\omega_0 = 1.0$, 最小权重 $\omega_{\min} = 0.3$, 惯性权重线性下降.
- 2) SA-COSO算法:参数与标准PSO算法一致.
- 3) HLBPSO算法:其优胜榜样学习概率为0.5, 自适应学习概率 $pc = 0.5(1 - t/T_{\max})^{[3]}$, 其他参数与标准PSO算法一致.
- 4) DIR-QPSO算法:主辅子群规模相同, $N_{s_1} = N_{s_2}^{[9]}$, 其他参数与标准PSO算法一致.
- 5) ILS-PSO算法:学习因子 $c = 2$, 可调系数 $\chi =$

0.95.

算法测试时,各算法独立运行30次,表2给出了测试函数维数为30时,上述5种算法优化结果的数值统计,图7给出了各测试函数的平均适应度下降曲线.

从算法的收敛能力看:ILS-PSO算法对所有测试函数均能很好地收敛;标准PSO算法对函数 f_3 、 f_4 和 f_7 完全无法收敛;SA-COSO算法与HLBPSO算法对函数 f_3 和 f_4 的收敛结果很差,对函数 f_7 则完全无法收敛;DIR-QPSO算法对函数 f_7 完全无法收敛.

相对于ILS-PSO算法,其他算法对于函数 f_3 、 f_4 和 f_7 难以收敛,主要是因为这3个函数都是极难搜索的. f_3 为变量间存在耦合的非凸病态函数,全局最小值位于狭窄的通道中的点 $x = (1, 1, \dots, 1)$ 处,一般的优化算法极难获得全局最小值; f_4 是一个具有大量局部极值的高维多峰函数,对优化算法有极强的欺骗性; f_7 是一个典型的欺骗函数,在 $x = (420.9687, 420.9687, \dots, 420.9687)$ 处取得全局最小值,全局最优点距离另一个局部最优点很远,一旦陷入局部最优,极难跳出^[3-5]. 由于ILS-PSO算法采用了多区域搜索的渐近式收敛策略,提高了算法的收敛能力,对函数 f_3 、 f_4 和 f_7 这类难以优化的函数也能很好地收敛,这正是本文所提出ILS-PSO算法的优势所在.

表2 数值统计结果

算法	统计特性	f_1	f_2	f_3	f_4	f_5	f_6	f_7	f_8	f_9
PSO	Mean	2.8939e-07	3.6425e-15	50.3765	72.0457	0.0664	2.8797	4.1976e+03	-16.7217	0.0232
	Std.	6.2204e-13	1.5427e-31	1231.4872	530.8914	0.0143	10.6484	1.0411e+06	3.1611	0.0036
	Best	2.1886e-09	2.6491e-21	24.6734	34.8235	5.3901e-13	1.3333	2.2639e+03	-20.3576	3.1844e-08
	Worst	2.5300e-06	4.3510e-10	96.2081	122.45031	0.5126	14.6045	6.3210e+03	-13.8040	0.2746
SA-COSO	Mean	2.1236e-48	3.2135e-51	11.2647	24.4996	2.5378e-43	1.3983	3.8390e+02	-17.9089	4.9482e-10
	Std.	1.4242e-72	2.6714e-87	135.6380	16.6822	1.9716e-76	0.4067	1.0861e+05	5.6093	1.3416e-21
	Best	3.3948e-56	2.0917e-55	3.1247	32.0883	0	0.2316	1.8182e+01	-24.206	2.5397e-18
	Worst	1.3276e-35	1.9835e-46	29.1093	21.2920	1.0983e-31	1.9324	7.4821e+02	-14.2056	3.2473e-06
HLBPSO	Mean	5.1362e-45	1.3252e-49	19.0459	17.9625	2.4575e-27	2.2209	1.6890e+03	-27.0391	1.5996e-14
	Std.	2.3421e-69	1.1106e-95	534.6524	10.4785	3.5821e-55	0.4974	6.0558e+04	12.3844	1.8128e-27
	Best	2.7592e-53	4.2221e-53	2.3766	12.9344	0	0.9313	1.1689e+03	-27.7233	7.5797e-16
	Worst	3.4672e-43	1.0536e-47	131.2764	22.8854	6.4272e-34	3.4038	1.9974e+03	-25.8109	1.4743e-13
DIR-QPSO	Mean	1.3213e-213	0	2.3414	6.29711	3.7126e-13	2.7395e-014	1.3183e+03	-28.8170	3.2575e-11
	Std.	5.3242e-316	0	8.1257	15.3562	2.5371e-15	7.2902e-018	7.2600e+06	0.1917	1.8979e-23
	Best	1.4761e-267	0	0.3126	4.1058	0	2.0192e-014	3.2862e+02	-29.0657	7.8903e-15
	Worst	4.2833e-187	0	6.2147	12.0668	1.2412e-17	4.3491e-014	3.2144e+03	-28.2094	2.3981e-9
ILS-PSO	Mean	0	0	0.0014	1.3124e-05	0	8.8818e-016	3.8188e-04	-28.4516	1.4324e-09
	Std.	0	0	3.8866e-07	3.1642e-08	0	0	4.6437e-09	0.31829	1.8488e-19
	Best	0	0	8.9952e-05	8.5862e-06	0	8.8818e-016	3.8185e-04	-29.0555	3.0384e-13
	Worst	0	0	0.0023	2.7563e-05	0	8.8818e-016	3.8194e-04	-27.8548	5.5689e-07

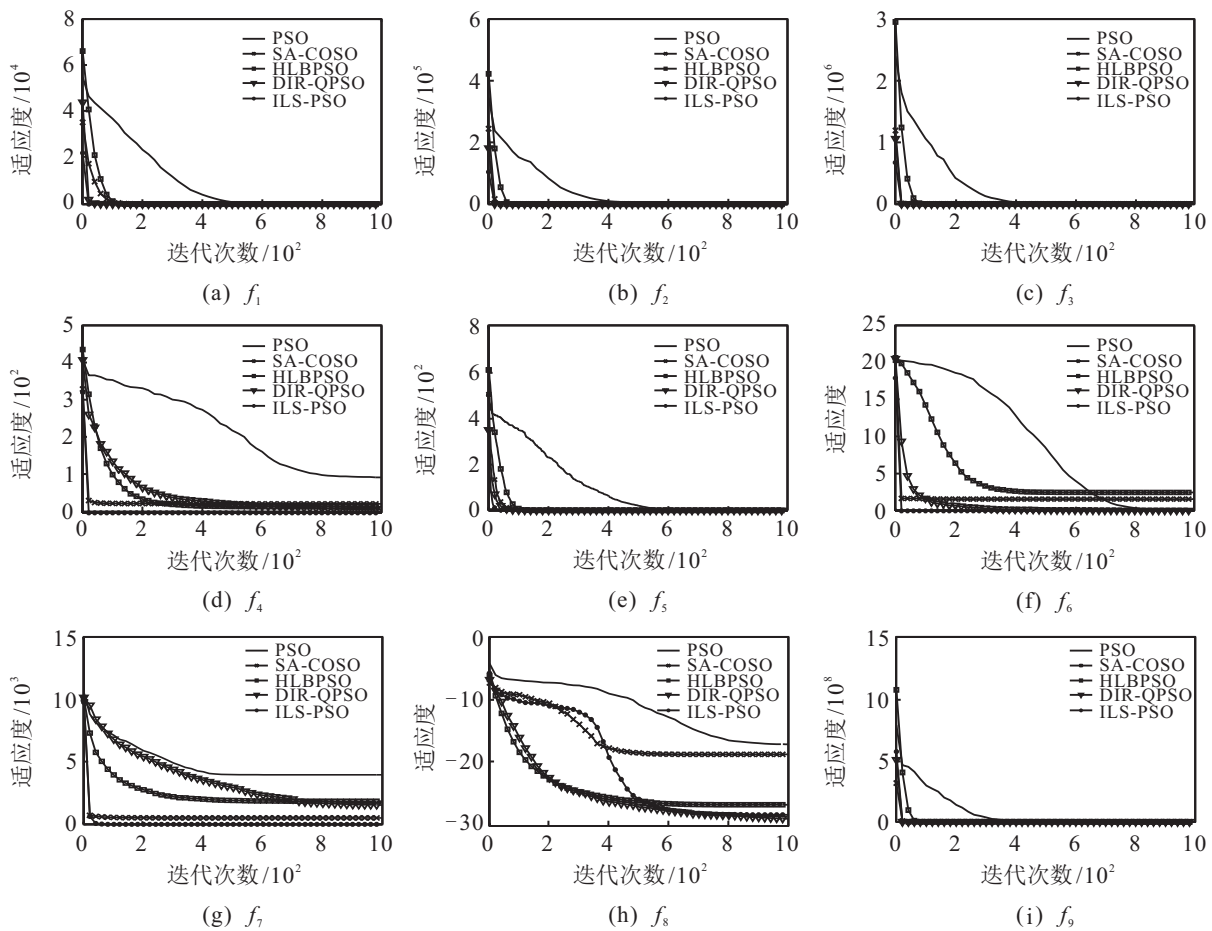


图7 测试函数平均适应度下降曲线

从算法的收敛精度看:对于函数 f_1 、 $f_3 \sim f_7$, ILS-PSO 算法的收敛精度最好;对于函数 f_2 , ILS-PSO 算法与 DIR-QPSO 算法的收敛精度一致;对于函数 f_8 , DIR-QPSO 算法的收敛精度最高, ILS-PSO 算法与之相近;对于函数 f_9 , HLBPSO 算法的收敛精度最高. 因此,对于不同的测试函数,这4种改进型 PSO 算法各有优点,对于 ILS-PSO 算法,由于加入了变步长搜索策略,后期搜索精细程度增加使其对于大部分测试函数的搜索结果更好一些.

对比各算法的收敛速度,由图7可见:无论对于单峰函数还是多峰函数,标准 PSO 算法的收敛速度都是最慢的;对于其他4种算法,其收敛速度会随着测试函数特性的变化而发生变化. 总体而言,ILS-PSO 算法和 SA-COSO 算法的收敛速度更快,HLBPSO 算法的收敛速度相对慢一些;但对于函数 f_8 , HLBPSO 算法和 DIR-QPSO 算法的收敛速度明显比其他算法快. 因此,从算法的收敛速度上看,各改进型 PSO 算法各有优点,而 ILS-PSO 算法的综合优势更强一些.

上述9个测试函数除 f_8 外,其他函数解的各维均相等,在实际工程应用中,所求问题解的各维一般不

相等,因此本文从表1中选取6个可进行偏移操作的函数 (f_1 、 f_2 和 $f_4 \sim f_7$) 进行偏移操作,偏移操作后各函数最优解的各维均不相等(各函数的最小值和搜索范围保持不变),更符合实际工程应用的情况. 新的偏移函数表达式如下:

1) Shifed Sphere

$$f_{10}(X) = \sum_{i=1}^D \left(x_i - \frac{i}{10}\right)^2.$$

2) Shifed DeJongF4

$$f_{11}(X) = \sum_{i=1}^D i \left(x_i - \frac{i}{10}\right)^4.$$

3) Shifed Rastrigrin

$$f_{12}(X) = \sum_{i=1}^D \left(x_i - \frac{i}{D}\right)^2 - 10 \cos \left[2\pi \left(x_i - \frac{i}{D}\right) + 10\right].$$

4) Shifed Griewank

$$f_{13}(X) = \sum_{i=1}^D \frac{(x_i - 0.1i)^2}{4000} + \prod_{i=1}^D \cos \left(\frac{x_i - 0.1i}{\sqrt{i}}\right) + 1.$$

5) Shifed Ackley

$$f_{14}(X) = -20 \exp\left(-0.2 \sqrt{\frac{1}{D} \sum_{i=1}^D \left(x_i - \frac{i}{D}\right)^2}\right) + 20 - \exp\left(\frac{1}{D} \cos\left[2\pi\left(x_i - \frac{i}{10}\right)\right]\right) + \exp(1).$$

6) Shifed Schwefel

$$f_{15}(X) = 418.9829D - \sum_{i=1}^D \left(x_i - \frac{i}{10}\right) \sin\left(\left|x_i - \frac{i}{10}\right|^{\frac{1}{2}}\right).$$

图8给出了ILS-PSO算法在不同维数下,对偏移函数优化结果的箱线统计图.对于每一个函数,算法独立运行30次,参数与前面的测试保持一致.

结合表2的数值统计结果和图8的箱线统计图可以看出:

1) 对于30维的函数,与基本函数相比,偏移函数

的优化精度有所降低,这主要是由于偏移函数求解更为复杂所造成的,提高解的精度可以通过增加算法迭代次数来解决.

2) 随着函数维数的增加,其优化精度逐步变差,这主要是由于维数增加,函数求解更加复杂造成的,该问题同样可以通过增加算法迭代次数来解决.

3) 除函数 f_{12} 外,ILS-PSO算法对于不同维数的偏移函数的求解精度是很好的.对于其他算法求解精度差而ILS-PSO算法求解精度很好的函数 f_4 ,ILS-PSO算法对其偏移函数 f_{12} 的求解精度明显变差,这体现了ILS-PSO算法的不足;但对于其他算法完全不能收敛的Schwefel函数,ILS-PSO算法对其基本函数 f_7 和偏移函数 f_{15} 均能很好地收敛,这体现了ILS-PSO算法的优势.

对于优化效果较差的函数 f_{12} ,使用SA-COSO算法、HLBPSO算法和DIR-QPSO算法进行对比测试,测试结果如图9所示.

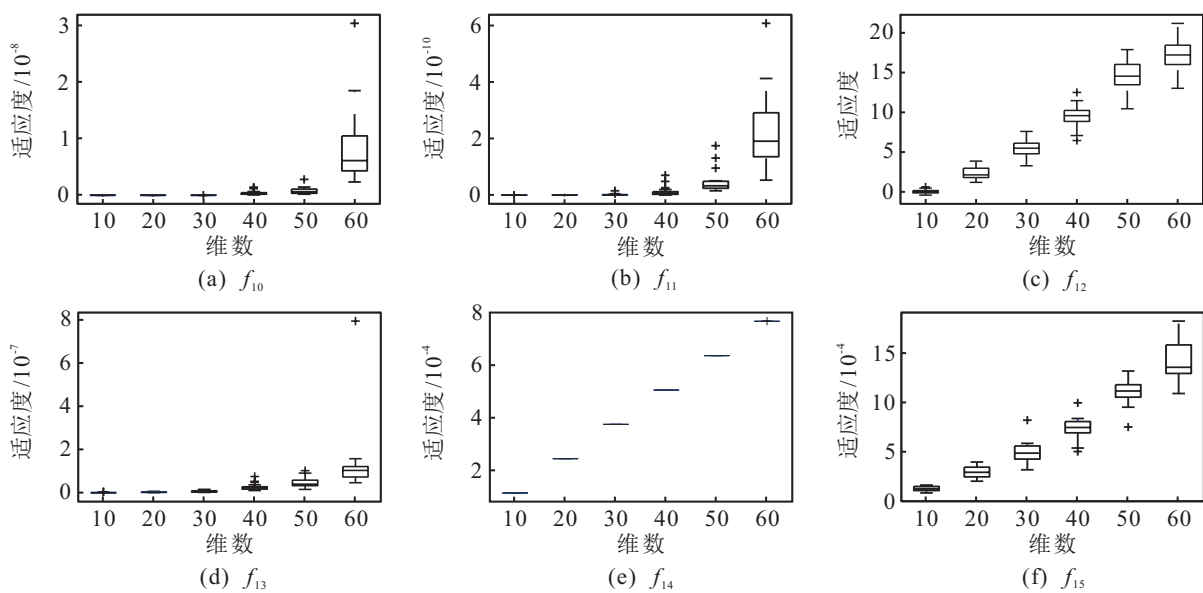


图8 不同维数偏移函数ILS-PSO算法优化结果箱线统计图




图9 不同算法对函数 f_{12} 的优化结果箱线统计图

对比图8(c)和图9可以看出,对于函数 f_4 的偏移函数 f_{12} ,ILS-PSO算法的优化结果仍然明显优于SA-COSO算法、HLBPSO算法和DIR-QPSO算法.这表明,对于某些特定函数的优化,基于PSO的改进算法

还需要进一步深入研究.

综上所述,对于文中大多数基本测试函数,ILS-PSO算法与其他算法相比,收敛速度较快,收敛精度更高.虽然个别函数的优化效果略差于HLBPSO算

法和SA-COSO算法,但对于其他算法收敛精度差或完全不能收敛的函数,ILS-PSO算法也能很好地收敛.对更符合实际应用场合的偏移函数的测试结果表明,ILS-PSO算法也能取得良好的优化效果(对于优化效果差的函数,其他算法的优化效果更差).数值测试结果体现出了ILS-PSO算法的优势,综合性能优于其他对比算法.

5 结论

本文提出了一种带有独立局部搜索机制和多区域渐近收敛的ILS-PSO算法.在ILS-PSO算法中,通过非劣解邻域的搜索公式,使算法能够更好地对多个可能的最优目标区域进行有效的搜索.通过简化参数的独立的全局搜索公式和局部搜索公式,克服了标准PSO算法全局搜索能力与局部搜索能力相互制约的缺点,降低了PSO算法因搜索后期种群多样性丧失而陷入局部最优的概率.单维扰动方式和变步长搜索策略的引入,提高了算法对当前最优解搜索的精细程度和搜索效率,改善了算法的求解精度和收敛速度.相对于标准PSO算法,ILS-PSO算法的初始参数减少1个,简化了算法参数设置.仿真测试结果表明,与文中对比算法相比,ILS-PSO算法具有良好的收敛速度、精度和更强的收敛能力,在对求解精度和速度要求较高的优化问题领域中有良好的应用前景.

参考文献(References)

- [1] Chan C L, Chen C L. A cautious PSO with conditional random[J]. Expert Systems with Applications an Int J, 2015, 42(8): 4120-4125.
- [2] Agrawal S, Silakari S. Fletcher-reeves based particle swarm optimization for multimodal[J]. Soft Computing, 2014, 18(11): 2227-2243.
- [3] 申元霞, 陈健, 曾传华. 层次学习骨干粒子群优化算法[J]. 控制与决策, 2016, 31(12): 2183-2188.
(Shen Y X, Chen J, Zeng C H. Hierarchical learning bare-bones particle swarm optimization algorithm[J]. Control and Decision, 2016, 31(12): 2183-2188.)
- [4] Qin Q, Cheng S, Zhang Q, et al. Particle swarm optimization with interswarm interactive learning strategy[J]. IEEE Trans on Cybernetics, 2016, 46(10): 2238-2251.
- [5] Jordehi A R. Enhanced leader PSO (ELPSO): A new PSO variant for solving global optimisation problems[J]. Applied Soft Computing, 2015, 26(26): 401-417.
- [6] Sun C, Jin Y, Cheng R, et al. Surrogate-assisted cooperative swarm optimization of high-dimensional expensive problems[J]. IEEE Trans on Evolutionary Computation, 2017, 21(4): 644-660.
- [7] 夏学文, 王博建, 金畅, 等. 一种自适应多种群的PSO算法[J]. 系统仿真学报, 2016, 28(12): 2887-2895.
(Xia X W, Wang B J, Jing C, et al. Self-adaptive multi-swarm particle swarm optimization [J]. J of System Simulation, 2016, 28(12): 2887-2895.)
- [8] Shabbir F, Omenzetter P. Particle swarm optimization with sequential niche technique for dynamic finite element model updating[J]. Computer-Aided Civil and Infrastructure Engineering, 2015, 30(5): 359-375.
- [9] 吴涛, 严余松, 陈曦. 基于随机评价机制的交互式双子群QPSO算法[J]. 控制与决策, 2015, 30(3): 526-530.
(Wu T, Yan Y S, Chen X. Improved dual-group interaction QPSO algorithm based on random evaluation [J]. Control and Decision, 2015, 30(3): 526-530.)
- [10] Garg H. A hybrid PSO-GA algorithm for constrained optimization problems[J]. Applied Mathematics & Computation, 2016, 274(11): 292-305.
- [11] Wang S, Zhang Y, Dong Z, et al. Feed-forward neural network optimized by hybridization of PSO and ABC for abnormal brain detection[J]. Int J of Imaging Systems & Technology, 2015, 25(2): 153-164.
- [12] Kaveh A, Mahdavi V R. A hybrid CBO-PSO algorithm for optimal design of truss structures with dynamic constraints[J]. Applied Soft Computing, 2015, 34(5): 260-273.
- [13] Mistry K, Zhang L, Neoh S C, et al. A micro-GA embedded PSO feature selection approach to intelligent facial emotion recognition[J]. IEEE Trans on Cybernetics, 2016, 99: 1-14.
- [14] Zhao F, Liu Y, Zhang C, et al. A self-adaptive harmony PSO search algorithm and its performance analysis[J]. Expert Systems with Applications, 2015, 42(21): 7436-7455.
- [15] Cesare N D, Chamoret D, Domaszewski M. A new hybrid PSO algorithm based on a stochastic Markov chain model[J]. Advances in Engineering Software, 2015, 90(C): 127-137.
- [16] Li C, Nguyen T T, Yang M, et al. An adaptive multipopulation framework for locating and tracking multiple optima[J]. IEEE Trans on Evolutionary Computation, 2016, 20(4): 590-605.
- [17] Sheng W, Chen S, Sheng M, et al. Adaptive multisubpopulation competition and multiniche crowding-based memetic algorithm for automatic data clustering[J]. IEEE Trans on Evolutionary Computation, 2016, 20(6): 838-858.
- [18] 田一明, 陈雪波, 孙秋柏. 行为安全管理系统中员工不安全行为涌现性抑制的研究[J]. 安全与环境学报, 2016, 16(2): 174-178.
(Tian Y M, Chen X B, Sun Q B. Study on the inhibitive tendency of the unsafe behavior inclination of the employees in the BBS management and control system[J]. J of Safety and Environment, 2016, 16(2): 174-178.)
- [19] Bai J, Liu H. Multi-objective artificial bee algorithm based on decomposition by PBI method[J]. Applied Intelligence, 2016, 45(4): 1-16.