

控制与决策

Control and Decision

基于多点加点准则的代理模型辅助社会学习微粒群算法

田杰, 孙超利, 谭瑛, 曾建潮

引用本文:

田杰, 孙超利, 谭瑛, 等. 基于多点加点准则的代理模型辅助社会学习微粒群算法[J]. *控制与决策*, 2020, 35(1): 131–138.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2018.0504>

您可能感兴趣的其他文章

Articles you may be interested in

[微电子生产过程调度问题基于指标快速预报的分解算法](#)

An indexes fast prediction based decomposition method for scheduling problem in microelectronic production process

控制与决策. 2020, 35(1): 139–146 <https://doi.org/10.13195/j.kzyjc.2018.0422>

[基于数据解析的连退生产过程多因子操作优化](#)

Multifactorial operation optimization for continuous annealing process based on data analytics

控制与决策. 2019, 34(12): 2713–2720 <https://doi.org/10.13195/j.kzyjc.2018.1581>

[利用种群扩张与稀疏化策略改进NSGA-II-DE算法](#)

Using population expansion and sparsity strategy to improve NSGA-II-DE algorithm

控制与决策. 2019, 34(1): 55–62 <https://doi.org/10.13195/j.kzyjc.2017.0973>

[多维广义次成分提取准则及自适应算法](#)

Multiple minor generalized eigenvectors extraction information and its adaptive algorithm

控制与决策. 2019, 34(1): 105–112 <https://doi.org/10.13195/j.kzyjc.2017.1028>

[解空间定向优化的快速免疫算法研究及其应用](#)

Research and application of fast immune algorithm for solution space directional optimization

控制与决策. 2017, 32(7): 1241–1246 <https://doi.org/10.13195/j.kzyjc.2016.0666>

[基于频繁覆盖策略的随机漂移粒子群优化算法](#)

Random drift particle swarm optimization with frequent coverage strategy

控制与决策. 2017, 32(12): 2127–2136 <https://doi.org/10.13195/j.kzyjc.2016.1402>

[改进差分进化算法在可靠性冗余分配问题中的应用](#)

Improved differential evolution algorithm for solving reliability redundancy allocation problem

控制与决策. 2015, 30(5): 917–922 <https://doi.org/10.13195/j.kzyjc.2014.0647>

[一种采用改进细菌觅食优化算法的图像增强方法](#)

Image enhancement method based on improved bacteria foraging optimization algorithm

控制与决策. 2015(3): 461–466 <https://doi.org/10.13195/j.kzyjc.2013.1794>

基于多点加点准则的代理模型辅助社会学习微粒群算法

田 杰^{1,2}, 孙超利^{3†}, 谭 瑛³, 曾建潮^{1,4}

(1. 太原科技大学 机械工程学院, 太原 030024; 2. 山东女子学院 数据科学与计算机学院, 济南 250300;
3. 太原科技大学 计算机科学与技术学院, 太原 030024; 4. 中北大学 计算机与控制工程学院, 太原 030051)

摘 要: 代理模型辅助的进化算法目前已广泛用于解决计算代价高的复杂优化问题. 然而, 大多数现有的代理模型辅助进化算法只适用于低维问题且仍然需要数千次昂贵的真实适应值评价来获得较优解. 为此, 提出一种基于多点加点准则的代理模型辅助的社会学习微粒群算法, 用于解决高维问题并使用更少的评价次数. 该算法选用高斯过程构造代理模型, 以社会学习微粒群算法 (SLPSO) 作为优化器, 提出一种基于相似度的多点加点规则 (SMIC), 用于选取需要使用原函数进行实际计算的候选解. 在仿真实验中将该方法与现有研究成果进行比较, 通过对 50 维 ~ 100 维的基准函数的测试, 验证了所提出算法在有限的适应值计算次数下拥有更好的寻优性能, 尤其是在高维优化问题上拥有更显著的优势.

关键词: 高维费时问题; 代理模型辅助的进化算法; 加点规则; 相似度; 代理模型

中图分类号: TP273

文献标志码: A

Similarity-based multipoint infill criterion for surrogate-assisted social learning particle swarm optimization

TIAN Jie^{1,2}, SUN Chao-li^{3†}, TAN Ying³, ZENG Jian-chao^{1,4}

(1. College of Mechanical Engineering, Taiyuan University of Science and Technology, Taiyuan 030024, China; 2. School of Data and Computer Science, Shandong Women's University, Jinan 250300, China; 3. Department of Computer Science and Technology, Taiyuan University of Science and Technology, Taiyuan 030024, China; 4. School of Computer Science and Control Engineering, North University of China, Taiyuan 030051, China)

Abstract: The research on surrogate-assisted evolutionary algorithms has attracted increasing attention for time or resource consuming optimization problems over the past decades. However, most existing surrogate-assisted evolutionary algorithms still require thousands of expensive function evaluations to obtain acceptable solutions and are only applied to low-dimensional problems. Therefore, a surrogate-assisted optimization, called SMIC-SLPSO (Similarity-based multipoint infill criterion for surrogate-assisted social learning particle swarm optimization), is proposed for high dimensional problems with less computation. In the proposed algorithm, using Gaussian process as the surrogate model and considering SLPSO algorithm as an optimizer, a similarity-based multipoint infill criterion (SMIC) is proposed for searching the solutions to re-evaluation by using the original expensive problems. Simulation of experiments comparing the proposed algorithm with a few state-of-the-art surrogate-assisted evolutionary algorithms on benchmark functions from 50 to 100 dimension is carried out. The results proposed algorithm is able to achieve better or competitive solutions with a limited budget of exact evaluations, especially on higher dimensional problems.

Keywords: high-dimensional expensive optimization; social learning particle swarm optimization; infill criterion; similarity; surrogate-model

0 引 言

群智能优化方法已被广泛应用于复杂工程优化中, 如大型电力系统^[1-2]、天线设计^[3-4]和航空航天及汽车设计问题等^[5-6], 在这些高维或大规模的复杂优

化问题中, 通常包含大量的决策变量, 存在优化难度大且优化时间过长的问题. 比如文献[7]中所提到的, 在汽车工业中进行一次防撞性分析平均约花费 98 个小时, 那么 1 024 次分析就要花费将近 12 年的时间来

收稿日期: 2018-04-21; 修回日期: 2018-06-15.

基金项目: 国家自然科学基金项目 (61472269, 61403272); 山西省自然科学基金项目 (201601D021083); 山东女子学院高水平科研项目 (2018GSPSJ07).

责任编辑: 王凌.

†通讯作者. E-mail: chaoli.sun@tyust.edu.cn.

完成. 因此,为了更好地解决上述费时问题,通常使用代理模型来辅助进化算法,用计算廉价的代理模型来替代昂贵的实际适应值评价. 目前常用的代理模型有响应面法(多项式回归)^[8-9]、高斯过程模型(GP,又称Kriging模型)^[10-11]、BP神经网络^[12]、径向基函数模型(RBF)^[13-14]以及支持向量机(SVM)^[15]等. 此外,文献[16]提出了一种基于核密度估计廉价代理模型的多算子搜索策略,用于在进化优化中对候选个体进行预筛选. 正如有关代理模型辅助进化的综述文献[17-18]中所提到的,代理模型辅助进化算法目前仍存在一些问题需要解决:如何提高模型的准确度以及模型管理问题. 模型管理又称之为加点准则,其核心思想是仅选择出部分候选解进行昂贵的适应值评价,而其他候选解的适应值则用廉价的代理模型进行估计^[19-20].

目前常用的加点准则有:目标函数最小值准则(MSP)^[21]、期望改进准则(EI)^[20,22]、改进概率最大值准则(PoI)^[23-25]及统计下限最小值准则(LCB)^[10,26]、均方差MSE准则^[27]. 除MSP准则适用于(如多项式回归、神经网络、径向基函数等)大多数代理模型外,EI、PoI、LCB、MSE准则一般只能适用于以高斯过程模型为代表的能够进行误差估计的模型或集成模型^[28]. Emmerich等^[29]在低维问题上(10维及20维)比较了MSP、EI、LCB这3个准则的性能,发现EI准则获得了较好的结果但比其他两个准则更费时. 近年来,一些其他的组合加点准则不断被提出,Chugh等^[30]在解决多目标问题时,同时使用了MSP及MSE准则. Liu等^[31]采用LCB准则解决了30维以下的问题,而在对50维的问题上采用了降维方法,先将高维问题降至4维的低维空间,然后再使用LCB准则,将实际函数的计算次数减少至1000次. 文献[32]针对低维问题提出了一种集成模型管理策略,在局部优化及全局优化的模型上分别应用MSP及MSE准则,并进一步将实际计算次数降为 $11D$, D 代表问题的维数,如30维的问题,在实际计算次数为330次时停止优化. 目前,在现有文献中,只有文献[33]将代理辅助的进化优化方法应用到了100维的高维问题上,其选用的加点准则为多种群集成模型下的MSP准则.

本文针对高维问题,提出一种新的自适应代理模型辅助优化算法. 在该算法中,提出了基于相似度的加点准则,选用GP模型为代理模型,SLPSO为优化器,并将适应值的实际计算次数进一步缩小至 $10D$,

选用与文献[33]相同的基准函数,在高维问题上验证本文所提出的优化策略的有效性.

1 目前技术及存在问题

1.1 高斯过程(GP)

GP模型的优势在于可以在给出预测值的同时给出该预测值的误差估计值,上文所提到的常用的加点准则均可应用于GP模型中. 因此,本文选用GP作为代理模型,但GP模型目前不能很好地应用于高维问题,除了引言中所提到的现有加点准则不能很好地适用于高维问题之外,随着训练样本的增加,GP模型构建变得更加耗时^[30-34]. 本文作者前期在如何构建GP模型能够满足精度的同时尽量提高效率的角度上作了一定的研究与尝试^[35]. 基于以上研究,在本文中,GP模型的具体构建方式如下:创建含有 n 个样本 $(\mathbf{x}_i, y_i)(i = 1, 2, \dots, n)$ 的数据库 A ,对任一候选解 \mathbf{x} 的适应值 y 在GP模型中被看作为 $\mu + \varepsilon(\mathbf{x})$,其中 $\varepsilon(\mathbf{x})$ 服从分布 $N(0, \sigma^2)$.

$$\mu = \mathbf{k}(\mathbf{x})\mathbf{K}^{-1}\mathbf{y}, \quad (1)$$

$$\sigma^2 = \kappa(\mathbf{x}) - \mathbf{k}(\mathbf{x})^T\mathbf{K}^{-1}\mathbf{k}(\mathbf{x}). \quad (2)$$

其中: \mathbf{K} 为矩阵且矩阵元素为 $K_{ij} = C(\mathbf{x}_i, \mathbf{x}_j)$,是以 \mathbf{x}_i 和 \mathbf{x}_j 两点间的欧氏距离作为参数的协方差值; $\mathbf{k}(\mathbf{x}) = [C(\mathbf{x}, \mathbf{x}_1), \dots, C(\mathbf{x}, \mathbf{x}_n)]^T$ 为一个 $n \times 1$ 的向量, $\mathbf{X} = (\mathbf{x}_1, \dots, \mathbf{x}_n)$ 为样本点的输入值; $\kappa(\mathbf{x}) = C(\mathbf{x}, \mathbf{x})$ 为 \mathbf{x} 自身的协方差, $C(\cdot, \cdot)$ 为协方差函数. 本文选用Matern32函数作为协方差函数,即

$$C(\mathbf{x}, \mathbf{x}_i) = k_{\text{Matern32}}(r) = \sigma_f^2 \left(1 + \frac{\sqrt{3}r}{\sigma_l}\right) \exp\left(-\frac{\sqrt{3}r}{\sigma_l}\right). \quad (3)$$

其中: $r = \sqrt{(\mathbf{x} - \mathbf{x}_i)^T(\mathbf{x} - \mathbf{x}_i)}$, σ_l 和 σ_f 为GP模型中的超参数. 本文采用序列二次规划^[36]来优化超参数,则候选解 \mathbf{x} 的预测值 $\hat{y}(\mathbf{x})$ 及用以度量预测值不确定性的方差 $s^2(\mathbf{x})$ 为

$$\hat{y}(\mathbf{x}) = \mu + \mathbf{k}(\mathbf{x})\mathbf{K}^{-1}(\mathbf{y} - \mathbf{I}\mu), \quad (4)$$

$$s^2(\mathbf{x}) = \sigma^2 \left(1 + \mathbf{k}^T(\mathbf{x})\mathbf{K}\mathbf{k}(\mathbf{x}) + \frac{(1 - \mathbf{I}^T\mathbf{K}^{-1}\mathbf{k}(\mathbf{x}))^2}{\mathbf{I}^T\mathbf{K}^{-1}\mathbf{I}}\right), \quad (5)$$

其中 \mathbf{I} 为 $n \times 1$ 的单位列向量.

1.2 社会学习微粒群算法(SLPSO)

标准微粒群算法因其在高维问题上容易早熟,而社会学习粒子群优化算法(SLPSO)在高维问题上性能较好^[37]. 所以,将SLPSO作为优化器产生候选解,

利用本文所提出的加点准则,选择符合条件的个体进行实际计算. 在SLPSO中,第 j 个个体在第 $t+1$ 代的进化公式如下:

$$x_{jd}(t+1) = \begin{cases} x_{jd}(t) + \Delta x_{jd}(t+1), & p_j(t) \leq P_j^L; \\ x_{jd}(t), & \text{otherwise;} \end{cases} \quad (6)$$

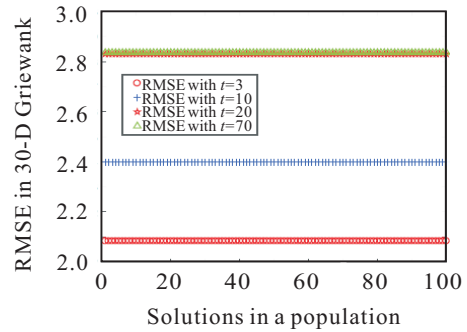
$$\Delta x_{jd}(t+1) = r_1 \Delta x_{jd}(t) + r_2 (x_{kd}(t) - x_{jd}(t)) + r_3 \varepsilon (\bar{x}_d(t) - x_{jd}(t)). \quad (7)$$

其中: $1 \leq j < m$, 个体 k 是个体 j 随机选择的学习者, 所以 $j < k \leq m$, 种群数 $m = 100 + D/10$; $x_{kd}(t)$ 表示个体 k 的第 d ($1 \leq d \leq D$, D 是决策空间的维数) 维分量. 值得注意的是, 个体 j 在每一维上的学习者 k 并不固定, 都是随机选择的. P_j^L 为与个体 j 的适应值成反比的学习概率值, $p_j(t)$ 为个体 j 生成的随机数, r_1, r_2 和 r_3 为 $[0, 1]$ 区间的随机数, $\bar{x}_d(t)$ 为当前种群在 d 维上的均值, ε 为用来控制 $\bar{x}_d(t)$ 影响力的社会影响因子.

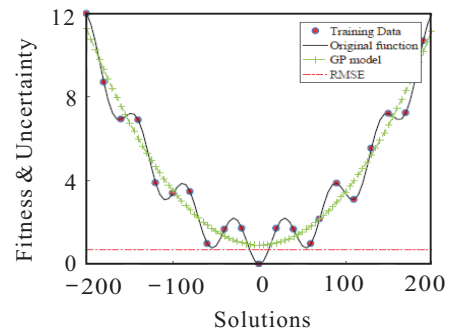
1.3 存在问题

在高维问题上, 代理模型主要存在两个问题: 1) 模型的精确度问题; 2) 模型预测不确定性的度量问题. 除MSP准则只用到函数预测适应值以外, EI、PoI、LCB、MSE准则的建立都需要用到模型提供的预测误差估计值. 通常将GP过程模型中提供的均方根误差(RMSE)作为候选解的预测误差估计, 但各个候选解的预测误差估计随着样本点的减少及维数的增高而变得难以区分. 这一现象用30维Griewank函数来具体说明. 由图1(a)可以看出: 在SLPSO的第3、第10、第20及第70代进化产生的100个候选解中, 各个候选解的RMSE均无差异. 说明在Griewank函数上各个解之间很难区分哪个误差更大, 因此, MSE准则在这种情况下就不再适用. 为进一步分析原因, 在整个决策空间 $[-200, 200]$ 选取20个等距测试样本点, 在1维的Griewank函数上进行测试, 如图1(b)所示, 不管预测值与实际函数值是否接近, 此时给出各个候选解的RMSE均相等. 在图1(c)中, 选取的30个样本点分别等距分布于决策空间 $[-200, -50]$ 及 $[50, 200]$, 而在区间 $[-50, 50]$ 中无采样样本点时, MSE才有所区分, 而在高维问题上, 选取的样本点密度不大于图1(b), 也很少出现图1(c)所示样本分布不均匀的极端情况. 所以, 出现了图1(a)中SLPSO在30维Griewank


函数上产生各个候选解的RMSE均无差异这一极端情况. 另一方面, 在EI、PoI、LCB等常用规则中, 实际是将解的预测值和预测误差估计值进行线性或者非线性加权处理, 因此这些规则, 也因为RMSE本身的价值很难区分而性能降低. 基于以上分析, 提出了一种基于相似度的加点准则, 使其能够在高维问题上可以不受RMSE误差估计不准确的影响挑选个体进行实际计算.



(a) 30维 Griewank 函数候选解的 RMSE



(b) 20个均匀样本点的 Griewank 函数预测



(c) 30个非均匀样本点 Griewank 函数预测

图1 Griewank函数的实际函数值、GP预测值及RMSE值比较分析

2 基于相似度的加点准则

2.1 相似度

本文所使用的相似度为候选解与构建模型样本间的相似度, 且在前期工作^[38]中作出了相关定义. 在文献^[38]中, 通过度量候选解与历史数据之间的相似度, 选取合适的骨干近邻对候选解通过适应值加权继承的方法进行赋值. 本文通过度量候选解与样本

之间的相似度来判断当前个体所处环境,通过当前个体与近邻的相似度来反映当前候选解的估计误差大小.基于假设候选解与样本间的相似度越小而候选解的预测值误差可能会越大的考虑,通过判断相似度的大小来选取合适的个体用原函数进行实际的适应值计算.将本文中所使用的相似度表述如下:首先,为当前代候选解划定邻域半径 \mathbf{R}_i ,则当前候选解的邻域空间 $U(\mathbf{x}_i, \mathbf{R}_i)$ 为 $[\mathbf{x}_i - \mathbf{R}_i, \mathbf{x}_i + \mathbf{R}_i]$. 候选解与数据库 A 中任意一个位于 $U(\mathbf{x}_i, \mathbf{R}_i)$ 邻域半径内的样本 r 的相似度为

$$\mu_i^r = e^{-\frac{(\mathbf{x}_r - \mathbf{x}_i)^2}{2\sigma^2}}, \quad (8)$$

$$\sigma = \frac{\beta}{\delta} \mathbf{R}_i, \quad (9)$$

$$\delta = \frac{\max_{r \in \{1, 2, \dots, k\}} (f(\mathbf{x}_r)) - \min_{r \in \{1, 2, \dots, k\}} (f(\mathbf{x}_r))}{\max_{ev \in \{1, 2, \dots, m\}} (f(\mathbf{x}_{ev})) - \min_{ev \in \{1, 2, \dots, m\}} (f(\mathbf{x}_{ev}))}. \quad (10)$$

其中: σ 为尺度参数, δ 为崎岖度,构建 GP 模型的数据库为 A , 且 $A = \{\mathbf{x}_{ev}, f(\mathbf{x}_{ev}), ev = 1, 2, \dots, m\}$, 从中选出位于候选解的邻域空间 $U(\mathbf{x}_i, \mathbf{R}_i)$ 内的样本, 这些样本构成 \mathbf{x}_i 的近邻集合 $\mathbf{X}_r = \{\mathbf{x}_r, f(\mathbf{x}_r), r = 1, 2, \dots, k\}$. \mathbf{x}_r 为第 r 个近邻的位置, $f(\mathbf{x}_r)$ 为 \mathbf{x}_r 的适应值. 若近邻个体的适应值变化范围较大, 则崎岖度相对较大; 若近邻个体的适应值变化范围较小, 则崎岖度相对较小. $\mu_i^{\max} = \max(\mu_i^r)$ 是个体 i 与近邻集合 $\mathbf{X}_r = \{\mathbf{x}_r, f(\mathbf{x}_r), r = 1, 2, \dots, k\}$ 的相似度最大值. 这里有一个特殊情况, 即当 $\mathbf{X}_r = \emptyset$ 时, $\mu_i^r = 0$ 且 $\mu_i^{\max} = 0$.

2.2 基于相似度的多点加点准则(SMIC)

算法1 基于相似度的多点加点准则(SMIC).

Input: 当前代种群 P , 种群大小 M , GP 模型预测值 F_{gp} 和个体 i 与近邻的最大相似度 μ_i^{\max} ;

Output: 实际计算的候选解及其适应值.

```

1 begin
2   for  $i=1 : M$  do
3     if  $\mu_i^{\max} = 0$  then
4        $\mathbf{x}_i \in SP_1$ ;
5     else
6        $\mathbf{x}_i \in SP_2$ ;
7     end
8   end for
9   从集合  $\mathbf{x}_i \in SP_1$  选取  $F_{gp}$  最优的个体进行实际计算;
```

```

10  在集合  $SP_2$  中分别选取  $F_{gp}$  最优的个体及相似度最小的个体进行实际计算;
```

```

11 end
```

算法1给出了基于相似度的多点加点准则算法的伪代码,通过相似度的大小,可以判断当前个体所处区域是否已经被勘探或开发. 本文将当前种群 P 分为集合 SP_1 和 SP_2 , 即 $P = SP_1 \cup SP_2$. 将 $\mu_i^{\max} = 0$ 的待估个体划分到集合 SP_1 , 所有 $\mu_i^{\max} > 0$ 的待估个体划分到集合 SP_2 . 当待估个体位于集合 SP_1 时, 待估个体所在区域尚未被勘探. 选取集合 SP_1 中预测值适应值最好的个体进行实际计算. 当待估个体的相似度大于0时, 待估个体所在区域已经被开发, 但根据相似度的大小可以粗略判定开发程度的不同. 在集合 SP_2 中分别选取预测适应值最好的个体及 μ_i^{\max} 最小的个体进行实际计算.

3 SMIC-SLPSO算法

算法2 SMIC-SLPSO算法.

Input: M 种群大小, 最大实际计算次数 $\max E$, 维数 D ;

Output: 当前最优值 Gbest.

```

1 begin
2   初始化种群  $P \leftarrow \text{Initialize}(M)$  并实际计算适应值  $F \leftarrow \text{Fit}(P)$ , 实际计算次数  $\text{Evatime} = M$ ;
3   创建数据库  $DB \leftarrow \{P : F\}$ ;
4   if  $N < 2 * D$  then
5     种群进化并计算适应值, 并将结果放入数据库  $DB \leftarrow DB \cup \{P : F\}$ ;
6   else
7     while  $\text{Evatime} \leq \max E$  do
8       从数据库  $DB$  中选择样本构建数据库  $A$ ;
9       利用数据库  $A$  构建 GP 模型, 并利用 GP 模型对种群  $P$  进行估值;
10      更新种群  $P$ ;
11      用 SMIC 加点准则选取  $n$  个候选解  $P_{eva}$  进行实际计算得到  $F_{eva}$ ,  $\text{Evatime} = \text{Evatime} + n$ ;
12      更新数据库  $DB \leftarrow DB \cup \{P_{eva} : F_{eva}\}$ ;
13      更新当前最优值 Gbest;
14    end while
15  end if
16 end
```

算法2展示了SMIC-SLPSO的算法框架的伪代码,代码行2为该算法用拉丁超立方体方法(Latin hypercube sampling)初始化种群,将初始种群使用原函数进行实际计算获得种群个体的适应值;在行3,将初始个体的位置及适应值存入数据库DB,后续将用于构建GP模型.行8至行9,使用从数据库DB选取最新的 N 个样本构建数据库A,用A中的所有样本来构建GP代理模型,并利用GP代理模型对新的候选解进行估值;行10中用SLPSO算法中的式(6)和(7)更新种群位置及速度,产生新的候选解;行11和行12,使用本文算法1所提出的SMIC加点准则,从被GP模型估值的候选解中,选取部分个体进行实际计算并加入到数据库DB中.行13,更新当前最优值.当达到最大实际计算次数时,将算法终止,输出当前最优值.

4 仿真实验及分析

4.1 测试函数

为了测试SMIC-SLPSO算法的有效性,本文选取了目前常用于算法比较的6个测试函数,其中包含经典测试函数及复杂测试函数,具体函数详见表1,函数公式参见文献[10, 39].实验中分别针对这6个函数的30维、50维、100维,与目前性能较优的GPEME^[10]及SACOSO^[33]算法进行性能比较,每个算法独立运行20次后进行结果统计.

表1 3个标准测试函数

编号	函数名称	测试维数	最优值
F_1	Ellipsoid	30/50/100	0
F_2	Rosenbrock	30/50/100	0
F_3	Ackley	30/50/100	0
F_4	Griewank	30/50/100	0
F_5	Shifted Rotated Rastrign	30/50/100	-330
F_6	Rotated Hybrid Composition Function(F19 in [39])	30/50/100	10

4.2 参数设定

SMIC-SLPSO算法涉及SLPSO算法的参数设定与文献[37]中相同,SMIC规则中计算相似度的参数设定与文献[38]相同.在50维及100维问题的适应值评价次数的最大值设定在 $10D$.当适应值评价次数达到最大值时,算法结束.用于训练代理模型的样本数为 N , N 的最小值设定在 $2D$,最大值设定在 $4D$,其中 D 为优化问题的维数.

4.3 不同维数上的结果比较

由现有文献可知,目前用于高维问题的代理模型辅助的进化算法有GPEME^[10]及SACOSO^[33].GPEME在50维函数优化中使用了降维技术,且在与

SACOSO的结果比较中也不占优势.因此,在30维上与GPEME进行了结果比较,结果如表2所示,SMIC-SLPSO算法在6个测试函数均获得了优于GPEME的优化结果.

表2 SMIC-SLPSO与GPEME在30维问题上的结果比较

函数	方法	均值	方差
F_1	GPEME	2.21e+02	8.16e+01
	SMIC-SLPSO	1.42e-01	1.39e-01
F_2	GPEME	2.58e+02	8.02e+02
	SMIC-SLPSO	2.70e+02	5.35e+01
F_3	GPEME	1.32e+01	1.58e+00
	SMIC-SLPSO	1.12e+01	1.14e+00
F_4	GPEME	3.66e+01	1.32e+01
	SMIC-SLPSO	1.80e-06	2.45e-06
F_5	GPEME	-2.19e+01	3.65e+01
	SMIC-SLPSO	-2.99e+01	3.32e+01
F_6	GPEME	9.59e+02	2.57e+01
	SMIC-SLPSO	8.21e+02	3.46e+01

为了进一步比较SMIC-SLPSO算法性能,选用性能优于GPEME的SACOSO分别在50维及100维的问题上作进一步的比较.同时增加基于3种不同加点准则的GP模型辅助的SLPSO算法:GP-MSP(使用MSP规则计算选取最优值个体),GP-EI(使用EI准则选取最大EI值个体)及GP-LCB(使用LCB准则选取最小LCB值个体).SMIC-SLPSO算法与这3个算法的区别仅在于加点准则的不同,SMIC-SLPSO算法使用了文中提到的SMIC加点准则.同时,将实际计算次数减少到 $10D$,其中 D 为候选解的维数.

由图2所示50维的收敛图比较结果可以看出,SMIC-SLPSO在 F_1 、 F_2 、 F_4 及 F_6 上均取得了明显优势,在 F_3 上仅次于GP-LCB算法,在 F_6 中SMIC-SLPSO与其他多个算法结果无明显差异.由图3可得,本文提出的SMIC-SLPSO在 F_1 、 F_2 、 F_4 及 F_5 上均取得了明显优势.在 F_3 函数上取得了与SACOSO及GP-MSP算法的结果无显著差异同时明显优于EI规则及LCB规则的结果,其主要原因在于 F_3 函数的最优点位于函数曲面上一个很狭长的山谷中,较容易被GP模型平滑掉.在 F_6 函数上仅次于SACOSO,但明显优于其他所有算法. F_6 函数为CEC05基准函数中的复合函数,函数较为复杂且较难拟合.综合30维、50维及100维的结果,在绝大多数函数优化中取得了优于其他算法的结果,且在100维的结果上较50维优势更明显.虽然 F_2 的均值在30维略低于GPEME算法,但方差明显低于GPEME算法,且在50维及100维的高维问题均取得了最优的结果,这也说明SMIC更适用于高维问题.

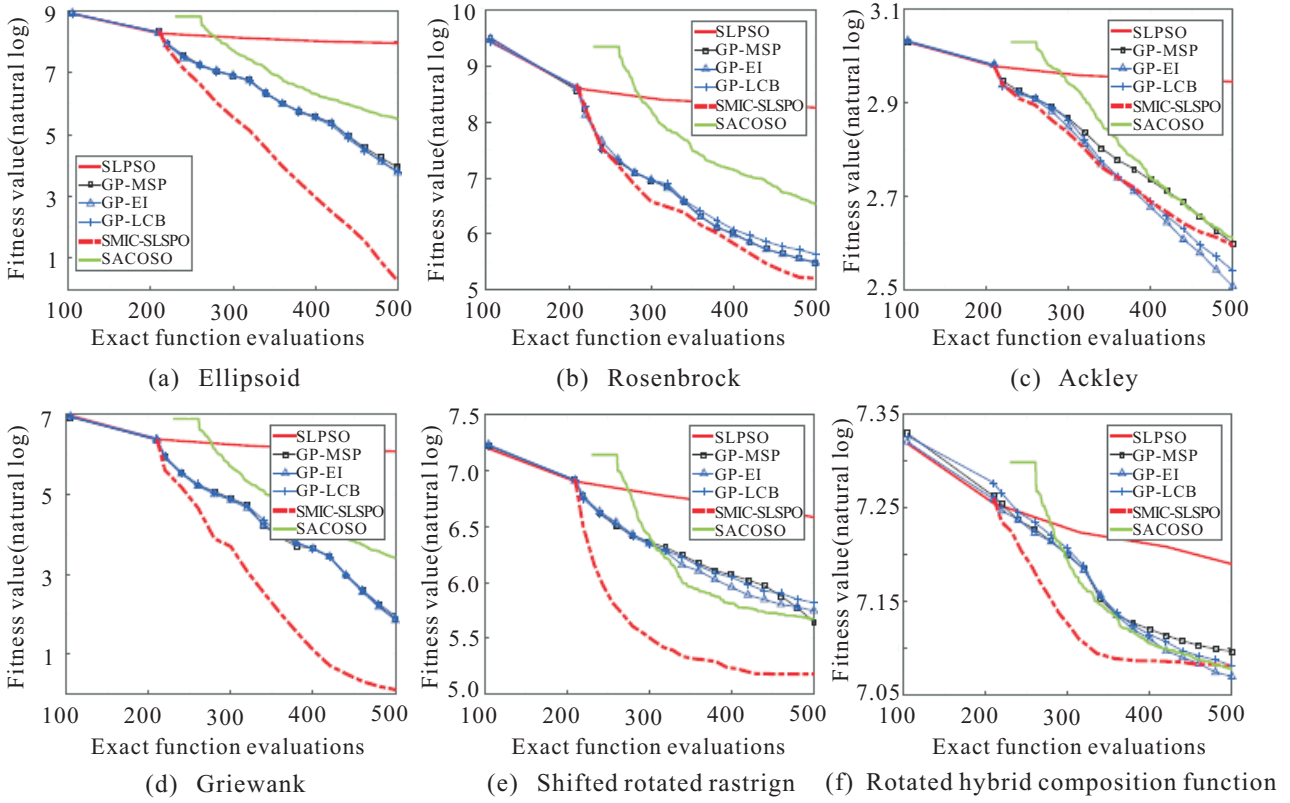


图2 50维函数收敛图

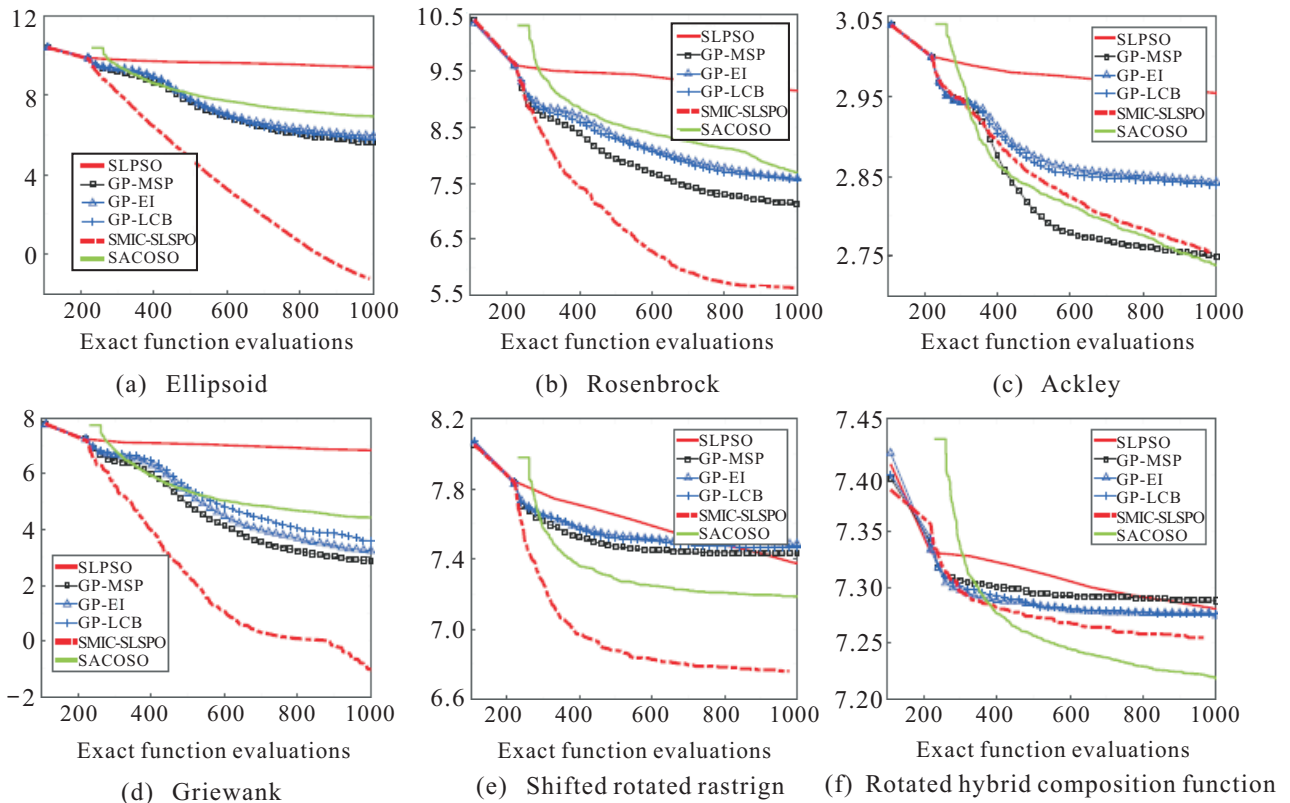


图3 100维函数收敛图

5 结论

为求解高维费时优化问题,本文提出了一种新的基于相似度的加点准则(SMIC),用于代理模型辅助的进化算法中.该加点准则不仅可以应用于文中

所使用的GP模型,同样可推广至使用RBF等其他模型.在解决高维问题上在更少的适应值评价次数下,SMIC-SLPSO具有明显优势,且算法的计算复杂度要低于SACOSO.在今后的研究中,拟将本文所提

出的基于相似度的加点准则结合其他代理模型(如RBF及SVM等)进一步验证该加点准则的性能,并将其应用于机械优化设计实例中,检验SMIC-SLPSO在工程问题中的实用性。

参考文献(References)

- [1] Del Valle Y, Venayagamoorthy G K, Mohagheghi S, et al. Particle swarm optimization: Basic concepts, variants and applications in power systems[J]. IEEE Trans on Evolutionary Computation, 2008, 12(2): 171-195.
- [2] Wang Y, Li B, Yuan B. Hybrid of comprehensive learning particle swarm optimization and SQP algorithm for large scale economic load dispatch optimization of power system[J]. Science China, 2010, 53(8): 1566-1573.
- [3] Soltani S, Murch R D. A compact planar printed MIMO antenna design[J]. IEEE Trans on Antennas & Propagation, 2015, 63(3): 1140-1149.
- [4] Milligan T A, Milligan T A, Milligan T A, et al. Modern antenna design[M]. New York: IEEE Press, 2005: 259-262.
- [5] Regis R G. Evolutionary programming for high-dimensional constrained expensive black-box optimization using radial basis functions[J]. IEEE Trans on Evolutionary Computation, 2014, 18(3): 326-347.
- [6] Ong Y S, Nair P B, Keane A J. Evolutionary optimization of computationally expensive problems via surrogate modeling[J]. Aiaa J, 2003, 41(4): 687-696.
- [7] Gu L. A comparison of polynomial based regression models in vehicle safety analysis[C]. ASME Design Engineering Technical Conferences. Pittsburgh, 2001: DAC-21063.
- [8] Zhou Z, Ong Y S, Nguyen M H, et al. A study on polynomial regression and Gaussian process global surrogate model in hierarchical surrogate-assisted evolutionary algorithm[C]. The 2005 IEEE Congress on Evolutionary Computation. Edinburgh: IEEE, 2005: 2832-2839.
- [9] Lim D, Ong Y S, Jin Y, et al. A study on metamodeling techniques, ensembles, and multi-surrogates in evolutionary computation[C]. Proc of Genetic and Evolutionary Computation Conference. London, 2007: 1288-1295.
- [10] Liu B, Zhang Q, Gielen G G E. A Gaussian process surrogate model assisted evolutionary algorithm for medium scale expensive optimization problems[J]. IEEE Trans on Evolutionary Computation, 2014, 18(2): 180-192.
- [11] Snoek J, Rippel O, Swersky K, et al. Scalable Bayesian optimization using deep neural networks[C]. Tnt Conf on Machine Learning. Life: Microtoma Publishing, 2015: 2171-2181.
- [12] 王凌, 吉利军, 郑大钟. 基于代理模型和遗传算法的仿真优化研究[J]. 控制与决策, 2004, 19(6): 626-630.
- (Wang L, Ji L J, Zheng D Z. Simulation optimization based on surrogate model and genetic algorithm[J]. Control and Decision, 2004, 19(6): 626-630.)
- [13] Sun C, Jin Y, Zeng J, et al. A two-layer surrogate-assisted particle swarm optimization algorithm[J]. Soft Computing, 2014, 19(6): 1461-1475.
- [14] Stramacchia M, Toal D, Keane A. Improving the optimisation performance of an ensemble of radial basis functions[C]. Engopt Int Conf on Engineering Optimization. Iguassu Falls: CAM, 2016: 1-8.
- [15] Deb K, Hussein R, Roy P, et al. Classifying metamodeling methods for evolutionary multi-objective optimization: First results[C]. Int Conf on Evolutionary Multi-Criterion Optimization. New York: Springer, 2017: 160-175.
- [16] Gong W, Zhou A, Cai Z. A multioperator search strategy based on cheap surrogate models for evolutionary optimization[J]. IEEE Trans on Evolutionary Computation, 2015, 19(5): 746-758.
- [17] Jin Y. A comprehensive survey of fitness approximation in evolutionary computation[J]. Soft Computing, 2005, 9(1): 3-12.
- [18] Jin Y. Surrogate-assisted evolutionary computation: Recent advances and future challenges[J]. Swarm & Evolutionary Computation, 2011, 1(2): 61-70.
- [19] Horn D, Wagner T, Biermann D, et al. Model-based multi-objective optimization: Taxonomy, multi-point proposal, toolbox and benchmark[C]. The 8th Int Conf on Evolutionary Multi-Criterion Optimization. Portugal: Springer, 2015: 64-78.
- [20] Ponweiser W, Wagner T, Vincze M. Clustered multiple generalized expected improvement: A novel infill sampling criterion for surrogate models[C]. Proc of the IEEE Congress on Evolutionary Computation. Hong Kong: IEEE, 2008: 3515-3522.
- [21] Koziel Slawomir, Leifur Leifsson, Xin-She Yang. Surrogate-based optimization[C]. Simulation-driven Design Optimization and Modeling for Microwave Engineering. London: Imperial College Press, 2013: 41-79.
- [22] Jones D R, Schonlau M, Welch W J. Efficient global optimization of expensive black-box functions[J]. J of Global Optimization, 1998, 13(4): 455-492.
- [23] Zhou Z, Ong Y S, Nair P B, et al. Combining global and local surrogate models to accelerate evolutionary optimization[J]. IEEE Trans on Systems, Man, & Cybernetics Part C, 2006, 37(1): 66-76.
- [24] Jones D R. A taxonomy of global optimization methods based on response surfaces[J]. J of Global Optimization, 2001, 21(4): 345-383.
- [25] Forrester A I J, Keane A J. Recent advances in surrogate-based optimization[J]. Progress in Aerospace Sciences, 2009, 45(1): 50-79.
- [26] Dennis J, Torczon V. Managing approximation models in optimization[C]. Multidisciplinary design optimization: State-of-the-Art. Philadelphia: SIAM, 1997: 330-347.

- [27] Sasena M J, Papalambros P, Goovaerts P. Exploration of metamodeling sampling criteria for constrained global optimization[J]. *Engineering Optimization*, 2002, 34(3): 263-278.
- [28] 孙晓燕, 巩敦卫. 自适应分区多代理模型交互式遗传算法[J]. *控制与决策*, 2009, 24(2): 170-175.
(Sun X Y, Gong D W. Interactive genetic algorithm with multiple surrogate models based on adaptive space division[J]. *Control and Decision*, 2009, 24(2): 170-175.)
- [29] Emmerich M T M, Giannakoglou K C, Naujoks B. Single- and multiobjective evolutionary optimization assisted by Gaussian random field metamodels[J]. *IEEE Trans on Evolutionary Computation*, 2006, 10(4): 421-439.
- [30] Chugh T, Jin Y, Miettinen K, et al. A surrogate-assisted reference vector guided evolutionary algorithm for computationally expensive many-objective optimization[J]. *IEEE Trans on Evolutionary Computation*, 2018, 22(1): 129-142.
- [31] Liu B, Yang H, Lancaster M J. Global optimization of microwave filters based on a surrogate model-assisted evolutionary algorithm[J]. *IEEE Trans on Microwave Theory and Techniques*, 2017, 65(6): 1976-1985.
- [32] Wang H, Jin Y, Doherty J. Committee-based active learning for surrogate-assisted particle swarm optimization of expensive problems[J]. *IEEE Trans on Cybernetics*, 2017, 47(9): 2664-2677.
- [33] 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.
- [34] Guo D, Jin Y, Ding J, et al. Heterogeneous ensemble based infill criterion for evolutionary multi-objective optimization of expensive problems[J]. *IEEE Trans on Cybernetics*, 2018, DOI: 10.1109/TCYB.2018.2794503.
- [35] Tian J, Sun C L, Zeng J C, et al. Comparisons of different kernels in Kriging-assisted evolutionary expensive optimization[C]. 2017 IEEE Symposium Series on Computational Intelligence (SSCI). Hawaii: IEEE, 2017: 1-8.
- [36] Nocedal J, Wright S J. *Numerical optimization*[M]. Springer Science Business Media. Berlin, 2006: 31-45.
- [37] Cheng R, Jin Y. A social learning particle swarm optimization algorithm for scalable optimization[J]. *Information Sciences*, 2015, 291(6): 43-60.
- [38] Tian J, Tan Y, Sun C L, et al. A self-adaptive similarity-based fitness approximation for evolutionary optimization[C]. 2016 IEEE Symposium Series on Computational Intelligence (SSCI). Greece: IEEE, 2016: 1-8.
- [39] Lim D, Jin Y, Ong Y-S, et al. Generalizing surrogate-assisted evolutionary computation[J]. *IEEE Trans on Evolutionary Computation*, 2010, 14(3): 329-355.

作者简介

田杰(1983—), 女, 讲师, 博士, 从事代理模型辅助的进化优化及其应用的研究, E-mail: tianjie1023@outlook.com;

孙超利(1976—), 女, 教授, 博士生导师, 从事群智能优化、微粒群算法、机器学习等研究, E-mail: chaoli.sun@tyust.edu.cn;

谭瑛(1965—), 女, 教授, 从事智能计算、数据库系统等研究, E-mail: Yingtany@126.com;

曾建潮(1963—), 男, 教授, 博士生导师, 从事智能计算、复杂系统等研究, E-mail: zengjianchao@263.net.

(责任编辑: 孙艺红)

《控制与决策》喜获“百种中国杰出学术期刊”称号

本刊讯: 2019年11月19日,由国家科学技术部中国科学技术信息研究所主办的“2018年中国科技论文统计结果发布会”在北京国际会议中心隆重举行,大会发布了2018年度中国科技论文统计结果和获奖名单.据《2018年版中国科技期刊引证报告(核心版)》(简称:《报告》)文献计量指标统计,全国自然科学类期刊共6718种,其中核心期刊2049种,归类于112个学科类别.东北大学主办的《控制与决策》在信息科学与系统科学类核心期刊中“核心影响因子”“综合评价

总分”均排名第1,被评为2018年度“百种中国杰出学术期刊”.这是《控制与决策》继2013年第6次被评选为“百种中国杰出学术期刊”以来,再次获此殊荣.

《报告》通过综合评价指标体系(25项学术计量指标),从各个角度对期刊进行统计描述和分析评价,客观地体现期刊的学术水平、学科地位和出版质量.“百种中国杰出学术期刊”是严格依据《报告》数据评选出的中国核心中英文学术期刊年度奖项,代表了中国学术期刊的最高水平.