群体智能优化中的虚拟碰撞: 雨林算法*

高维尚¹⁾ 邵诚¹⁾²⁾ 高琴^{1)†}

(大達理工大学控制科学与工程学院,大连 116024)
 (大连理工大学先进控制技术研究所,大连 116024)
 (2013年1月4日收到;2013年7月2日收到修改稿)

启发式优化算法中寻优代理过早收敛易陷入局部最优.本文对此进行机理分析并发现,虚拟碰撞作为一种隐性 过早收敛现象将直接影响群体智能优化算法的准确性与快速性,而采样过程的无约束性和样本分布信息的缺失是 导致虚拟碰撞的根本原因.为解决上述问题,本文提出雨林优化算法.该算法仿照植物生长模式,利用规模可变种群 代替规模限定种群进行分区分级寻优采样,并结合均匀与非均匀采样原则来权衡优化算法的探索与挖掘,可以有效 减少虚拟碰撞的发生,在提高寻优效率的同时,获取精准性和稳定性较高的全局最优解.与遗传算法、粒子群算法 对标称函数的寻优对比实验表明,雨林算法在快速性、准确性以及泛化能力等方面均具有优势.

关键词:优化算法,群体智能,进化计算,计算智能 PACS: 02.60.Pn, 87.55.kd, 89.20.Ff, 07.05.Mh

1引言

自从 Beni 和 Wang^[1] 于 1989 年提出群体智能 (SI)^[2,3] 这一概念之后,关于生物的集体行为及其自 组织方式的众多研究,充分展示了仿生优化算法在 非凸或者其它复杂优化问题中的需求与应用^[4-9]. 其中,由 Kennedy 和 Eberhart^[10] 于 1995 提出的粒 子群算法 (PSO) 在解决多峰优化问题 [11-13] 上表 现突出. 然而, 经典 PSO 的过早收敛^[14] 和优化结 果的低可靠度[15](多次重复试验结果往往有所不 同) 严重影响到 PSO 的实际应用, 这一问题在其他 群体智能优化算法中同样存在. 为提高经典 PSO 的全局寻优能力,许多关于 PSO 的改进 [16-18] 应 运而生,并且,相继出现针对粒子个体间的拓扑结 构^[19]的研究.这些工作曾大力推进了 PSO 的发展 与应用, 其中 Shi, Eberhart^[20] 以及 Trelea^[21] 所做的 研究能够有效指导我们在实际应用中选择合适类 型的 PSO 及相关参数. 但是, 以上改进在大多数情 况下只能作为算法某一环节的补充 [22],并不是界 定算法寻优行为特点的本质所属. 鉴于此, Marco A. DOI: 10.7498/aps.62.190202

然而,以上改进仍然受限于原始 PSO 的速度与 位置更新规则及其基本操作模式,这使得以往 PSO 只能关注两次相邻迭代过程中个体之间的位置关 系^[17], 而对整个迭代寻优过程中, 所有个体的位置 关系难以控制,从而易导致两个或者更多个粒子点 在探索阶段先后访问到同一个较小区域,形成一种 隐性过早收敛现象.这种先后不可控的历史位置关 系在许多群体智能优化算法中同样存在,并且是导 致时间资源浪费和寻优结果不可靠的重要原因.为 了更好地刻画这一现象,本文将首次引入"虚拟碰 撞"来形容粒子个体之间当前位置以及历史位置的 冲突. 虚拟碰撞的发生并不是偶然现象, 它对以往 群体智能优化算法有重要影响:首先,虚拟碰撞在 多数群体寻优过程中是不可避免的;其次,虚拟碰 撞在算法的探索阶段具有负面影响;最后,虚拟碰 撞在寻优挖掘阶段是适度需要的. 以粒子群算法为

Montes de Oca 等^[22]于 2009年通过重新组合方式, 集成优化以往有效的改进方案,并最终获得一个表 现优异的 Frankenstein's PSO. 此外, Poli^[23]所提供 的文献综述中列举了其他众多学者在推进 PSO 发 展方面所作出的杰出贡献.

^{*}国家自然科学基金(批准号:61074020)资助的课题

[†]通讯作者. E-mail: onlygaoqin@gmail.com

例:首先,由于控制粒子采样点位置更新的动态方 程没有充分考虑当前粒子与众多其他粒子之间的 位置关系,尤其是当前点与历史点之间的位置关系, 从而导致新粒子点落入其他粒子点 (包括历史粒子 点) 所能代表的有效邻域, 发生虚拟碰撞; 其次, 当 某一个粒子完成对某一区域的适应度评估后,与其 发生虚拟碰撞的粒子将造成采样冗余,另外,粒子 点在某一区域的集中极易造成在其他区域留下较 大空白区域而未能得到充分的探索;最后,众多粒 子点集中在最优区域内碰撞、采样并挖掘出最优 点是寻优算法提高精度的一种方式,如何避免繁多 的虚拟碰撞并以较少的粒子代理获得较充分的挖 掘也是算法设计的重要目标之一.虽然一些独立的 技术已经被应用于防止粒子群的过度集中,例如拥 挤度预估方法 [24] 和小生境模型 [25] 等,但它们的基 本启发模式并没有改变,不能从根本上防止不必要 的虚拟碰撞发生.

为有效避免虚拟碰撞的发生,本文提出一种全 新的可以全程调控采样分布的种群进化模式 —— 雨林算法. 该算法仿照植物的生长与进化模式, 通 过构建人工树,以尽可能少的枝叶探索并占领尽可 能广阔而优良的寻优空间.其中,每片叶子代表一 个采样点(相当于粒子群中某一时刻的一个粒子 点),每一段树枝代表采样点之间的距离.在该算法 的进化计算过程中,不同的采样点群将围绕上一代 所保留的不同母结点,按照不同的范围和间距展开 新一轮的采样.其中采样代理在不同群体中的分布 数量与密度能够根据探索信息进行动态调整. 另外, 雨林算法以出色的植物自适应性生长模式为指导, 通过调节枝叶的均匀与非均匀分部,能够根据实际 情况更加合理地处理寻优过程中探索与挖掘之间 的权衡. 通过证明, 本文发现在未知空间的均匀采 样是同一规模下最为有效的探索方式.本文还针对 这一新的寻优模式给出了有效的环境评估方法,并 用于调节新生枝叶的范围与数量,从而实现由均匀 采样到非均匀采样的合理过渡.实验结果表明,雨 林算法不但能解决以往群体智能寻优算法所固有 的虚拟碰撞问题,还能更为合理地动态调控寻优过 程中的探索与挖掘问题,进而让该算法的寻优更为 准确、高效和灵活.

雨林算法为智能群体优化提供了一个全新的 并行优化框架,在这一框架下简单采样个体以群体 模式按照不同密度和规模分布在决策空间中,并通 过模拟树木生长方式来寻找最优决策变量.

2 虚拟碰撞

当两个或两个以上寻优代理之间的相对距离 小于由关键域(将在下一小节定义)所支承的"安全 距离"时,我们称这些代理之间发生了虚拟碰撞.这 个定义所基于的条件是代理个体的属性能够代表 其所在区域的适应度状况,即众多群体智能寻优算 法的前提条件.

不失一般性,和"虚拟碰撞"相关的现象在自然 界中普遍存在,而且,许多生物在经历虚拟碰撞的 过程中获得适合自身特性及生存环境的解决方法: 一类是在虚拟碰撞发生后,通过激烈的搏斗来争夺 与维护各自的生存领域,如动物;另一类是在虚拟 碰撞发生前,凭借祖辈进化中所保留下来的合理分 布模式,来尽量避免虚拟碰撞的发生,如植物.不难 发现,严重的虚拟碰撞往往发生在运动性较好的动 物之间,而轻微的虚拟碰撞经常发生在运动性较好的动 物之间,而轻微的虚拟碰撞经常发生在运动性较差 的植物之间.这是因为缓慢的生长运动给植物带来 更充分的调节时间,从而使得枝叶分布更合理更有 效.本文正是受这一方面的启发,通过模拟植物的 生长方式来进行寻优采样,从而有效减少虚拟碰撞 所造成的采样资源的浪费.

2.1 虚拟碰撞的产生

为便于分析这一问题,本文只针对连续优化问题并引入"关键域"的概念:目标函数中一个或者 多个具有全局最优值的凸区域,并且该区域内的目标函数值都要比其他区域的较优.如图1所示,原 来的关键区域被裁剪为内部的一个矩形以方便后 期的数学计算.在寻优探索阶段,当且仅当某一采 样点落入这一区域,算法才能被正确引领到全局最 优凸域,进而才能挖掘到全局最优解,所以本文称 之为关键域或突现域.因此,本文能够利用关键域 这一概念,从新的而且更明确的角度来分析寻优 结果的全局可靠性:当最大采样空白区域的大小 能被包含在关键域内时,最优结果的全局性可以得 到保证.

基于以上分析可得,寻优探索过程中采样点的 间距不必过小,只要中间容不下关键域大小的空白 就能保证探索到全局最优区域 — 本文称之为突 现条件.所以,每个采样点都被赋予一个面(针对二 维决策变量)属性,即以该点为中心,以关键域为大 小的势力范围.当采样点的势力范围相邻时,就可 以满足突现条件.如果一个或多个采样点进入另一 个采样点的势力范围之内,我们称之为发生了虚拟 碰撞.正如自然界中的动物群体活动,许多群体智 能优化算法(粒子群算法仿照鸟群,鱼群算法仿照 鱼类,蜂群算法仿照蜜蜂)中的采样群体频繁出现 势力范围的交叉并导致虚拟碰撞.



图 1 二维寻优空间中的突现域

2.2 虚拟碰撞的不可避免性

 \boldsymbol{x}_2

群体智能优化算法的探索过程在整个寻优过 程中占有重要地位,受虚拟碰撞的影响较大,所以, 本章节将通过分析群体智能算法的机理方式,来说 明以往群体智能寻优在探索阶段无法避免虚拟碰 撞发生的特点. 目前群体智能算法在寻优探索过程中很难避 免虚拟碰撞的发生,根本原因在于其共同的机理模 式:代理个体根据当前群体采样信息,在某一启发 方式激励下,根据少数特殊代理信息估算新的采样 位置,然后更新群体方位,进入下一轮循环.这种模 式缺少两类重要信息的描述,即当前代理和历史代 理的位置关系以及当前代理中全部代理的位置关 系.因此,许多代理相互之间是不可见的,算法无法 确保它们下一时刻的位置关系.另外,这种机理模 式对代理个体的方位无明显约束,理论上每个代理 到达寻优全局,同时,多数群体智能算法在启发方 式中引入了随机因素以获取更好的泛化能力,但这 使得个体活动更为自由.综上所述,代理个体之间 位置关系(尤其是历史位置关系)的缺失和代理个 体无约束的自由运动必然导致虚拟碰撞的发生.

以遗传算法为例,其寻优代理 — 染色体的更 新机理^[26,27]包括:交叉(基因重组)与变异(基因突 变),并未考虑新生染色体与其他新旧个体间的距离 关系,而且新生个体的方位有较强的随机性.这种 无约束的伴随机变动在经历若干世代进化后,其代 理个体在决策空间中的运动轨迹较为广阔而杂乱, 如图 2 所示,显然虚拟碰撞在遗传算法的寻优探索 中是不可避免的.





再以粒子群算法为例,其动态更新机理如下 式^[28]所示:

$$\boldsymbol{v}_{i+1} = \boldsymbol{\omega} \boldsymbol{v}_i + \boldsymbol{U}(0, \boldsymbol{\varphi}_1) \otimes (\boldsymbol{p}_i - \boldsymbol{x}_i)$$

$$+ \boldsymbol{U}(0, \boldsymbol{\varphi}_2) \otimes (\boldsymbol{p}_{\mathrm{g}} - \boldsymbol{x}_i),$$
 (1a)

$$x_{i+1} = x_i + v_{i+1}.$$
 (1b)

当前粒子点的运动仅受自身个体最优方位 (*p_i*) 与 全局整体最优方位 (*p_g*) 的吸引, 而与其他个体的当 前位置及历史位置无关.虽然粒子代理单元的特征 属性和动态迭代方式都比较简单,但要想彻底掌握 全部粒子点在寻优过程中的运动和分布还是很困 难的^[29].另外每个粒子点的位置在决策空间中没 有限制,同时在速度更新机理中依然引入了随机因 素,使得粒子运动的更加自由,如图3所示.由此可 见,在粒子群算法的状态更新机理中,也存在新旧 个体之间位置关系的缺失和个体无约束的自由运 动,这些将导致新粒子位置 x_{n,i+1} 与其他粒子位置 $x_{m,i-k}(m! = n, 0 \leq k < i)$ 之间的距离无法控制,当某 一粒子点闯入其他粒子点(包括旧粒子点)的势力 范围内时,虚拟碰撞便会发生.

2.3 虚拟碰撞的负面影响

一方面, 虚拟碰撞将造成采样资源的浪费. 在 虚拟碰撞中,采样个体所代表的势力范围会重叠, 这些重叠的区域就意为着重复采样. 另一方面, 虚 拟碰撞为寻优结果带来极大的不确定性.发生虚拟 碰撞的代理个体之间过小的距离会反向拉长与别 的采样点之间的距离,导致较大凸空白区域的出现. 不失一般性,假设某二维目标函数的可行域大小为 S,采样点数 N 不变,并将决策空间分割为大小不 等的 M 个凸空白区域, 其大小为 s_i ($i = 1, 2, \dots, M$), 显然 $s_1 + s_2 + \cdots + s_M = S$. 那么当虚拟碰撞发生时, 一定存在 sm1 急剧减少和 sm2 急剧增加的情况,其 中面积较大的凸空白区域将成为遗漏突现域的可 能,从而导致寻优结果的全局可靠性下降.

本文以遗传算法和粒子群算法这两个较为成 熟并被广泛使用的算法为例,通过对比两者在以下 六个具有不同特点的标称目标函数的寻优表现,来 说明虚拟碰撞次数与算法效率的关系.这些标称函 数如表1所示,对比结果如表2所示.显然寻优时 间与虚拟碰撞的次数存在一定的正比例关系.

2.4 如何有效避免虚拟碰撞的发生

为有效避免虚拟碰撞的发生,本文仿照植物的 生长与进化模式,提出全局的分区管理与局部的分 级采样相互结合的策略.一方面,分区管理采样可 以在很大程度上约束代理个体的全局自由行为.某 一代理个体只能在本区域内进行采样活动,从而有 效避免了与其它区域内代理个体的虚拟碰撞.另一 方面,局部的分级采样策略是指由疏到密逐层分布

PSO在Shubert中的无约束行为

 x_1

 $\overline{10}$



图 3 粒子群算法的无约束运动

5

-5

表1 相关标称函数说明

函数名称	函数表达式	最优目标	
Griewank ^[30]	$f(X) = \frac{1}{1} \sum_{i=1}^{D} x_{i}^{2} - \prod_{i=1}^{D} \cos\left(\frac{x_{d}}{x_{d}}\right) + 1$	$X=(0,0,\cdots,0)$	
	$4000 \underset{d=1}{\overset{a}{\rightharpoonup}} \overset{a}{} \underset{d=1}{\overset{a}{\frown}} \left(\sqrt{d} \right)$	f(X) = 0	
Needle-in-a-haystack ^[31]	$f(X) = -\{3/[0.05 + (x_1^2 + x_2^2)]\}^2 - (x_1^2 + x_2^2)^2$	X = (0,0)	
		f(X) = -3600	
Rastrigin ^[30]	$f(X) = \sum_{l=1}^{D} [x_d^2 - 10\cos(2\pi x_d) + 10]$	$X = (0, 0, \cdots, 0)$	
	$\int (-)^{a} \sum_{d=1}^{a} \left[-a - a - a - a - a - a - a - a - a - a$	f(X) = 0	
Rosenbrock ^[30]	$f(X) = \sum_{l=1}^{D-1} [100(x_{d+1} - x_d^2)^2 + (x_d - 1)^2]$	$X = (1, 1, \cdots, 1)$	
	d=1	f(X) = 0	
Schaffer ^[30]	$f(X) = 0.5 + \frac{\sin^2 \sqrt{x_1^2 + x_2^2} - 0.5}{(x_1^2 - x_2^2)^2}$	$X = (0, 0, \cdots, 0)$	
	$(1+0.001\cdot(x_1^2+x_2^2))^2$	f(X) = 0	
Shubert ^[32]	$f(X) = \prod_{i=1}^{D} \sum_{j=1}^{5} i \cdot \cos[(i+1)x_{i}+i]$	当 D=2 时,有多个解	
	$\int (-7)^{n} \prod_{i=1}^{n} \sum_{j=1}^{n} \int \int \partial \partial f_i \left[(j+1) \partial f_i + j \right]$	$f_{\min}(X) = -186.7309$	

			表 2 GA 与 PSO 对标称函数进行寻忧的结果对比								
遗传算法寻优结果		粒子群算法寻优结果									
虚拟碰撞次数	消耗时间资源/s	虚拟碰撞次数	消耗时间资源/s								
16980	1.517230	5158	0.216093								
8869	1.584612	1974	0.263336								
939	1.364812	122	0.472258								
2712	1.381406	146	0.265603								
23847	1.374791	574	0.247545								
96	1.511696	26	0.232194								
	遗传算法 虚拟碰撞次数 16980 8869 939 2712 23847 96	遗传算法寻优结果 虚拟碰撞次数 消耗时间资源/s 16980 1.517230 8869 1.584612 939 1.364812 2712 1.381406 23847 1.374791 96 1.511696	遗传算法寻优结果 粒子群算 虚拟碰撞次数 消耗时间资源/s 虚拟碰撞次数 16980 1.517230 5158 8869 1.584612 1974 939 1.364812 122 2712 1.381406 146 23847 1.374791 574 96 1.511696 26								

物理学报 Acta Phys. Sin. Vol. 62, No. 19 (2013) 190202

采样点,由新的采样点来填充上一级采样空白.这 样可以很好地建立新旧采样点之间的位置关系,从 而避免绝大多数的虚拟碰撞.

全局的分区管理与局部的分级采样结合的目 的是为了能够动态适应未知目标函数的复杂分布. 不同的区域可以分为多个等级进行不同密度的采 样;局部的分级采样也可以在小范围内再进一步分 区以突出重点. 由此, 所有代理个体的采样位置与 行为趋势都可以根据已知采样信息做适当调整,以 适应寻优过程的不同阶段和目标函数的不同区域 对探索和挖掘的特殊需求.

3 权衡探索与挖掘的手段

在众多群体智能优化算法中,对探索与挖掘的 权衡将直接影响寻优的效率与准确度.如何利用有 限的采样资源并根据目标函数的实际情况,在不同 区域合理分配探索与挖掘的份量,是群体智能优化 算法要解决的难点和重点之一. 以往群体智能优化 算法通常会在寻优初期通过分散的代理群体展开 全局探索,然后逐渐转变为通过集中代理群体展开 局部挖掘. 而在本文, 鉴于虚拟碰撞的存在与影响, 通过研究发现均匀采样更加贴近寻优探索的目的, 而向非均匀采样的过渡,更能全面地说明算法向局 部挖掘的转变过程. 所以,本文将提出均匀采样与 非均匀采样这两个原则.

3.1 在未知区域的均匀采样

本文通过证明发现均匀采样是一种最有效的 探索未知区域的方式, 而群体智能优化算法前期在 全局的分散采样是一种近似均匀采样. 合理的探索 是让可行域中的最大采样空白最小化,以保证至少 有一个采样点落入关键域内.如图4和图5所示, 利用相同数量的样本点,均匀采样所留下的最大空 白较小.



不失一般性,假设:

1) 全局等概率分布有一个关键域 (突现域);

2) 关键域简化超立方体的各棱长为 h, l2, …,

 l_d ;

3) 可行空间各边的长度为 r₁, r₂, …, r_d;

4) 边缘效应可以忽略;

5)
$$C_i = r_i/l_i, (i = 1, 2, \dots, d), C = C_1 \times C_2 \times \dots \times C_d.$$

那么有

$$P_{\rm r} = 1 - \left(\frac{C-1}{C}\right)^n,\tag{2}$$

$$P_{\rm u} = \begin{cases} \frac{n}{C}, & n < C, \\ 1, & n \ge C, \end{cases}$$
(3)

其中 P. 表示在全局随机分布的 n 个独立采样点中, 至少有一个点在关键域的概率; Pu 表示在全局均匀

分布的 n 个采样点中,至少有一个点在关键域的概率; 当采样点数量 n 一定时, Pr 总是小于 Pu.

证明:

首先,针对全局随机分布采样点的情况,任意 一个采样点不能落入关键域的概率是 (1-1/C), 由于采样点都是独立分布的,所以 n 个采样点 都没有落入关键域的概率是 $(1-1/C)^n$,那么 $P_r = 1 - (1-1/C)^n$,(2) 式得证.

其次,针对全局均匀分布采样点的情况,如图 6 所示,n个均匀分布的采样点是固定的,而关键域是 等概率分布的.如果关键域的中心能够落入以样本 点为中心,以关键域为大小的虚线方框中,那么该 样本点也就落入了这一关键域内.由于某一固定采 样点能落入关键域的概率为 1/C,那么当 n < C 时, 至少有一个采样点落入关键域的概率 Pu = n/C;当 n≥C 即均匀采样密度足够大时,Pu = 1,(3) 式得证.



图 6 均匀采样与突现域

最后, 比较两者的大小. 当 $n \ge C$ 时, $P_r < P_u$ 显然成立. 当n < C时, 那么我们先比较n = 1的情况,可得 $P_r = P_u = 1/C$. 然后我们比较函数 P_r 与 P_u 以n为自变量的递增速度, 可得

$$P_{\rm r}' = -\left(\frac{C-1}{C}\right)^n \times \ln\left(\frac{C-1}{C}\right),$$
$$P_{\rm u}' = \frac{1}{C}.$$

令
$$x = 1 - 1/C$$
, 可得

$$P_{\rm r}' = -x^n \times \ln x$$

$$P'_{\rm u} = 1 - x,$$

其中 0 < x < 1, n 属于自然数. 令 $F_n(x) = P'_u - P'_r$ 可得

$$F_n(x) = 1 - x + x^n \times \ln x,$$

$$F'_n(x) = x^{n-1}(1 + n \times \ln x) - 1.$$

因为 $0 < x^{n-1} \leq 1$ 并且 $1+n \times \ln x < 1$,所以 $x^{n-1}(1+n \times \ln x) - 1 < 0$,那么 $F_n(x)$ 是一个关于x严格单调 递减的函数,满足 $F_n(x) > F_n(1) = 0$ (0 < x < 1),即 $P'_u > P'_r$.

综上所述,对于任意大于1的自然数 *n*都有 *P*_r < *P*_u, 原命题得证.

3.2 根据已知采样信息的非均匀采样

均匀采样 (如图 7 所示) 的最优特性只针对信息未知或者较少的区域有效, 经过一段均匀采样之后, 所反馈的函数分布信息应该指导算法向非均匀 采样过渡, 加快局部优势区域的采样进度. 如图 8 所示, 这种类似枝叶生长的方式能避免样本点数量 的指数增长, 提高最优点突现的速率.

非均匀采样原则建立在均匀采样信息之上,它 体现了一种筛选机制.正如几位探险者要在地球上 寻找最高的山峰,他们会将更多的精力放在高原上, 而不会在平原或者盆地花费大量搜索时间.这里的 高原、平原、盆地代表着前期探索所获得的采样 信息.随着采样信息的增加,算法向非均匀采样的 过渡将能够正确引导针对局部最优区域的挖掘.



190202-6

非均匀采样的形成过程

图 8

 \bigcirc

在实际应用中,均匀采样和非均匀采样应该交 叉进行,合理分配算法的探索与挖掘:一方面,在优 势区域按照非均匀采样原则进行挖掘的同时,在其 他区域按照均匀采样原则进行探索;另一方面,在 局部挖掘区域内的采样空白处按照探索方式进行 均匀采样搜索.从整体来看,非均匀采样是由不同 区域和密度的均匀采样组成,从而为算法提供更为 准确、高效的探索与挖掘.

4 雨林算法

经过前面的分析,我们不但得知在以往群体智 能算法中虚拟碰撞产生的原因和不良影响,而且还 给出更有效的调控寻优探索与挖掘的途径.在机理 分析的基础上,本文已经建立了全局分区管理与局 部分级采样的策略和均匀采样与非均匀采样原则, 目的是避免采样寻优过程中的虚拟碰撞,并明确权 衡寻优探索与挖掘的方式,这些都是以往群体智能 算法中不具备的.本章节将基于以上分析,通过模 仿林木生长的启发模式,构建一个全新而高效的群 体寻优方式 — 雨林算法.

4.1 林木的生长进化特点

林木的生长进化过程能够充分体现避免虚拟 碰撞的策略和权衡探索与挖掘的原则.如图9所示 为树的基本轮廓与抽象模型.

首先,树作为林木的主要单元占据一定生存区 域并展开适合自身环境的生长方式,而且树与树之 间的交叉碰撞并不多见,如图 10 所示.另外,树中 的各个子树之间也拥有各自的生长空间,如图 11 所示.这些均符合全局分区管理策略. 其次,树的枝叶满足顺序逐级分布特征.树的 宏观结构可以分为初期、中期和后期三个阶层,如 图 12 所示,结点分布先发散后收敛,这一点与多数 群体智能寻优算法的代理分布相符合.另外树的动 态生长过程也在逐级变化,如图 13 所示,层级越低, 枝长越短,结点所代表的势力范围越小.

最后,枝叶的整体分布具有向光性,而局部叶 结点的生长却呈对称或交错的均匀分布.这一点体 现了均匀采样原则与非均匀采样原则的结合,即非 均匀采样是由不同区域和密度的均匀采样组成,从 而可以让植物优化资源利用,引导枝叶进行高效的 空间探索与挖掘.



图 9 树的基本轮廓与抽象模型



图 10 树与树之间的无交叉分界



图 11 树与子树的组成关系





4.2 概念定义

4.2.1 采样价值

计算采样价值是对当前所有采样代理适应度 的动态归一化处理:

$$V_{i,j} = \frac{F_{i,j} - F_{\min,j}}{F_{\max,j} - F_{\min,j}},$$

(*i* = 1,2,...*n*; *j* = 1,2,...,*t*), (4)
$$V_{s,i,j} = \frac{F_{s,i,j} - F_{\min,i,j}}{F_{\max,i,j} - F_{\min,i,j}},$$

$$(s = 1, 2, \cdots, m; i = 1, 2, \cdots, n; j = 1, 2, \cdots, t),$$
 (5)

其中 $V_{i,j}$ 是指树 *i* 在全局第*j* 次迭代中所获得的采 样价值, $F_{i,j}$ 是树 *i* 在第*j* 次迭代中所获得的适应度 (本文选择树中最优枝叶的适应度来代表该树的适 应度), $F_{\max,j}$ 和 $F_{\min,j}$ 分别指第*j* 次迭代中全局所 有树的最大与最小适应度; $V_{s,i,j}$ 是指树 *i* 中的枝叶 *s* 在全局第*j* 次迭代中所获得的采样价值, $F_{s,i,j}$ 是 树 *i* 中的枝叶 *s* 在第*j* 次迭代中所获得的适应度, $F_{\max,i,j}$ 和 $F_{\min,i,j}$ 分别指在第*j* 次迭代中树 *i* 上所有 枝叶的最大与最小适应度.

4.2.2 信息熵与信息价值

信息熵 (*H*) 表示样本点对其周边环境评估可 靠度的量化,其定义为如下:

$$H_R = 1 - e^{-q}, \quad (q \in [0,\infty)),$$

其中 R 是指信息熵所针对的某一区域的样本集合, q 是对被评估区域的采样次数.显然,采样点越多, 获取的信息越可靠.针对全局采样的信息熵,总体 采样次数将随着迭代过程的延续而不断增加,因此, 本文将使用信息熵的近似形式:

$$H = 1 - e^{-t}, \quad (t \in [0, \infty)),$$
 (6)

未生长成被淘

其中, t 代表迭代次数, H 代表针对全局的采样信息熵.



图 13 模型树的生长

信息价值表示不完全可靠的环境评估对采样 价值的弱化,其定义如下:

$$V^{\rm H} = V \times H, (V \in [0, 1]),$$
 (7)

这种弱化是依据采样信息可靠度对当前采样价值 所进行的动态校正.信息价值将在雨林算法的寻优 过程中起重要作用,尤其是在寻优初期阶段,采样 点数量相对较少,样本点的适应度所能反映出的环 境信息与真实情况很可能有非常大的出入,为了避免前期采样信息的误导,较低的信息熵将会充分弱 化不同采样点之间适应度的差异,从而能够有效避 免采样点群过早陷入局部最优点.

4.3 算法规则

雨林算法通过构建人工树,将树的根、杈、叶

分别抽象为隶属于某一树集合(简称"树")的代理 群体,并将树或者子树的代理数量作为可控的算法 因子;同时,将树枝的长度抽象为代理范围,并作为 另一类可控的算法因子.雨林算法的运作方式是通 过控制以上两类算法因子,在不同区域引导不同密 度的均匀与非均匀采样分布.雨林算法的各个组成 均与寻优的探索与挖掘相关,如图 14 所示.图中, 雨林算法的运作方式还包含两部分运筹规则:行为 规则与评估规则.

运筹规则的第一部分,针对不同寻优区域和阶段的代理行为规则:1)环境分布越复杂,分配代理数量越多;2)环境适应度越高,新生采样群体的范围越小;3)环境分布信息越清晰,保留采样母结点的数量越少.将该行为规则转化为雨林算法的动态方程可表示如下:

$$r_{k,i,j} = \frac{1}{3} \times \left[(1 - \alpha) \times r_{k,i,j-1} + \alpha \times r_{k,i,j-1} \right]$$
$$\times e^{1 - 2V_{i,j-1}^{H}}, \qquad (8a)$$

$$r_{k,s,i,j} = (1 - \alpha) \times r_{k,i,j} + \alpha \times r_{k,i,j}$$
$$\times e^{1 - 2V_{s,i,j-1}}, \qquad (8b)$$

$$n_{k,i,j} = (1 - \alpha) \times n_{k,i,j-1} + \alpha \times n_{k,i,j-1} \\ \times \left[\frac{\arctan(R_{i,j-1}^{\mathbf{C}})}{\pi} \times 3 + \frac{1}{2} \right],$$
(8c)

$$n_{k,s,i,j} = (1 - \alpha) \times n_{k,i,j} + \alpha \times n_{k,i,j}$$
$$\times e^{2V_{s,i,j-1} - 1}, \tag{8d}$$

$$nn_{k,i,j} = (1 - \alpha) \times nn_{k,i,j-1} + \alpha \times n_{k,i,j} \times e^{-H},$$
 (8e)

其中, *i*, *j*, *k*, *s* 分别是集合树、迭代次数、决策空间 维和母结点 (代理) 的标示, *n*, *r*, *nn* 分别表示代理数 量、代理范围与保留的母结点数量. α 为学习因子, 可人工设定. *V* 是采样价值, 由 (4) 和 (5) 式计算. *R*^C, *V*^H 和 *H* 作为信息评估项将在评估规则中介绍.

$$R_{i,j}^{C} = \begin{cases} \frac{V_{i,j}^{C}}{V_{i,j-1}^{C}} = \frac{V_{i,j}^{O} - V_{i,j-1}^{O}}{V_{i,j-1}^{O} - V_{i,j-2}^{O}}, \\ (V_{i,j-1}^{O} - V_{i,j-2}^{O} \neq 0), \\ 0, (V_{i,j-1}^{O} - V_{i,j-2}^{O} = 0, V_{i,j}^{O} - V_{i,j-1}^{O} = 0), \\ 1, (V_{i,j-1}^{O} - V_{i,j-2}^{O} = 0, V_{i,j}^{O} - V_{i,j-1}^{O} \neq 0). \end{cases}$$

$$(9)$$

运筹规则的第二部分,针对不同寻优区域和阶段的信息评估规则:1)利用采样群组的采样价值变化率(*R*^C)代表环境复杂度;2)选择区域内最优的采样信息价值 *V*^H代表该区域的环境适应度水平; 3)使用信息熵 *H* 代表环境分布信息的清晰度.其中 *R*^C, *V*^O 和 *H* 分别按照(9),(7)和(6)式计算,而(9) 式中 *V*^O_{*i*,*j*}指的是树*i*在第*j*次迭代过程中所获得的 最优采样价值,由(4)和(5)式计算.该评估规则将 配合行为规则一起调整代理数量与代理范围的分 配,根据寻优过程中的实际情况来动态设定探索与 挖掘的程度,从而让雨林算法达到较为理想的速度 与准确度,如图 15 所示.





4.4 算法流程

基于雨林的生长特点,以及算法的代理行为与 信息评估规则,本节将给出雨林算法的具体流程:

1) 播种, 在可行域 r1×r2×···×rd 中以阵列形 式播撒 n1×n2×···×nd 个样本点, 这些样本点都 将作为树的种子, 生根发芽, 并以该种子为根结点 向外伸展枝叶. 播种的同时初始化枝叶的基础步长 $r_{k,i,j} = \frac{r_k}{n_k - 1}$ 、 枝叶数量 $n_{k,i,j} = 3$ 和母结点保留数 量 $n_{k,i,j} = 1$.

2) 萌发, 根据当前信息熵和各母结点的适应度 计算当前各母结点的采样价值 V_{s,i,j-1} 与和树的信 息价值 V^H_{i,j-1}, 然后计算树的采样价值变化率 R^C_{i,j-1}, 最后根据这些评估信息规划下一次迭代中围绕母 结点而新生的采样点数量 n_{k,s,i,j} 与伸展范围 r_{k,s,i,j}. 3) 生长, 按照萌发过程计算所得的新生枝叶的 数量与范围, 以各个母结点为中心开始展开新一轮 的采样, 并实时更新信息熵 *H*.

4) 竞争, 通过模拟植物之间的生存竞争, 仅保 留 *nn_{k,i,j}* 个较优代理作为下一代的母结点, 使得优 势群体获得更为良好的生存空间.

5) 计寿, 如果人工树在最近几次迭代过程中所 获得的最优适应度有所增加, 那么算法将带着当前 雨林所保留的母结点转入第二步的萌发阶段继续 新一轮的采样, 年龄加 "1", 否则, 算法将向下继续 第六步的进化阶段.

6) 繁衍, 判断程序是否满足结束条件, 如果没有, 则转入第一步的播种阶段, 重新初始化更多的树, 对全局进行更细致的划分, 以期获得更准确的 全局最优解; 如果程序满足结束条件, 那么, 输出全局最优结果, 结束群体寻优过程.

以上所述雨林算法有三个重要动态环节:第 一,时变的寻优个体数量,可以实时权衡算法寻优 的速度与准确度; 第二, 逐渐缩小的群体伸展范围, 不但可以实现算法寻优由探索向挖掘的合理过渡, 而且还可以有效避免虚拟碰撞的发生; 第三, 在生 存竞争中不断更新的母结点的数量与分布, 确保 雨林整体向更优的方向发展. 这三组重要动态环 节都源自前面几个章节对植物的生长与进化过程 的研究.

5 实验结果测评

本章节主要从算法的准确度、速度和泛化能 力三个方面,并通过与粒子群算法 (PSO) 和遗传 算法 (GA) 的比较,给予雨林算法较为全面而客观 评价.为避免实验对比的片面性,本次测评选用 六个常用并且特征不同的标称函数: Griewank^[30], Needle-in-a-haystack^[31], Rastrigin^[30], Rosenbrock^[30], Schaffer^[30]和 Shubert^[32],其适应度分布 (决策变量 为二维时) 如图 16所示.



图 15 执行规则、评价规则与算法功能的关系

关于遗传算法 (GA), 其初始化参数设置如下:

1) 群体数量: 100;

2) 变异概率: 0.05.

关于粒子群算法 (PSO), 其初始化参数设置 如下:

1) 群体数量: 40;

2) 惯性系数 (ω): 初始为 1, 然后随着寻优迭代

过程的进展,逐渐从1降低至0.1;

3) 动态方程如(1) 式所示.

关于雨林算法 (RFA), 其初始化参数设置如下:

- 1) 群体数量: 4×4;
- 2) 学习因子 (α): 0.5;
- 3) 动态方程如公式 (8) 所示.

虽然雨林算法 (RFA) 的动态方程要比粒子群

算法的动态方程复杂,但它一次可以计算多个采 样点的位置,所以这并不影响其整体运算量与寻 优速度.

5.1 寻优速度对比

为公平起见,本文提出采样时间与优化时间相 结合方式来评测算法的寻优速度.采样时间是指样 本点根据自身坐标计算适应度时所花费时间的累 积,它可以屏蔽程度编辑、运行环境以及其他额外 因素对寻优速度的影响,给出算法的理论速度;优 化时间是指在所有外部因素的干扰下,程序的整体运行时间,它可以考查程序设计的精简度,给出算法的实际速度.由于每个样本的采样时间基本相同(使用同一目标函数),使用采样个数来代替采样时间可以简化实验统计.

如图 17 所示为三个寻优算法在六个标称目标 函数中的最优值突现历程,其中雨林算法 (RFA) 与 粒子群算法 (PSO) 的寻优速度比较接近,而且比遗 传算法 (GA) 的寻优速度快.虽然有时 RFA 在前期 的最优值突现速度较慢,但是到后期,往往能率先



图 16 标称函数的空间分布

达到全局最优. 这是因为本次实验所设计的雨林算 法在前期比较重视全局探索, 以确保寻优结果的准 确性, 而后当采样信息充足时又能迅速转入局部的 挖掘, 从而能够快速而准确地找到全局最优点, 即 稳中求快.

为进一步考核 RFA 程序的时间复杂度,本文同时给出各算法在相同计算机环境下的优化时间对比,如表 3 所示.

显然,雨林算法在这次比较中表现最快.在第 一次比较的结果中可以看出粒子群算法与雨林算 法所花费的采样点数很接近,但是,粒子群算法需 要逐个分配每个采样点的坐标,而雨林算法却能够 通过代理范围与数量一次规划多个采样点的方位, 利用空间复杂度换取大量时间资源.

5.2 寻优准确度对比

高精确度与全局可靠度是评价优化算法准确 度的双重指标.表3已经说明在一定时限中PSO 和RFA所得结果最接近全局最优,有时RFA会比 PSO更准确一点.通过机理分析可得,PSO与RFA



图 17 各算法在标称函数中寻优的速度比较

拥有较高精确度的原因在于其后期较强的挖掘收 敛能力,而 RFA 还拥有较强的全局探索能力,能够 更好地避免陷入局部最优区域.例如在对 Needle 和 Schaffer 这类极具欺骗性的标称函数进行寻优 时, RFA 通常可以摆脱局部最优点的吸引并找到 全局最优值,而 PSO 则会偶尔陷入局部最优区域. GA 虽然也拥有较强的全局探索能力,但其在全局 最优区域内的挖掘力度不够,很难得到较为精确 的解.

为便于分析各算法的探索能力,本文还记录了测试过程中算法采样在不同标称函数中的分布,如

图 18 所示: 从第一列到第三列分别为 GA, PSO 和 RFA 的样本点记录; 从第一行到第六行分别表示针 对不同标称函数的采样, 顺序与前面的介绍一致. 显然, GA 具备最强的全局探索能力, 但却受限于后 期较弱的收敛能力, 所得结果的可靠性而不精确; PSO 的全局探索力度最小, 但却拥有快速的收敛能 力, 所得结果精确而不可靠; RFA 不但能够兼顾寻 优的探索与挖掘, 而且其采样点的聚集分布还能反 映出目标函数的极值分布特征, 这说明 RFA 对目标 极值 (包括全局最优值) 的探索是有效的, 所得结果 既可靠又精确.

表3 各算法在标称函数中日	的寻优结果对比
---------------	---------

目标函数 .	遗传算法寻优结果		粒子群算法寻优结果		雨林算法寻优结果	
	最优值	消耗时间资源/s	最优值	消耗时间资源/s	最优值	消耗时间资源/s
Griewank	0.0046	1.517230	0.0073	0.216093	0.0000	0.043495
Needle-in-a-haystack	-3537.9	1.584612	-3600	0.263336	-3600	0.042507
Rastrigin	0.0448	1.364812	0.0000	0.472258	0.0000	0.043403
Rosenbrock	0.0070	1.381406	0.0000	0.265603	0.0000	0.064963
Schaffer	0.0076	1.374791	0.0097	0.247545	0.0000	0.061069
Shubert	-186.4210	1.511696	-186.7309	0.232194	-186.7309	0.058665

5.3 算法的泛化能力

RFA 的泛化能体现在对六个不同特性的标称 函数的成功寻优,说明 RFA 能够将良好的寻优特 性推广到不同的寻优环境中来.其中,目标函数 Rastrigin, Rosenbrock 与 Griewank 侧重对算法挖掘 能力的测试,而另外三个目标函数侧重对算法探索 能力的测试.由于 RFA 能够在探索中包含挖掘,并 且利用并行挖掘来加强探索,这种探索与挖掘的相 铺相成能够让 RFA 在不同环境中都能表现出良好 的快速性与准确性,从所获得良好的泛化能力.

RFA 的泛化能力得益于自身的智能调整,而且 该算法在探索过程中对虚拟碰撞的有效避免可以 说明 RFA 更加智能.图 18 中的采样分布直观地反 映了各算法的虚拟碰撞情况:GA 的过度探索在全 局分配大量密集采样,极易发生虚拟碰撞并造成探 索资源的浪费;PSO 的全局收敛过程在挖掘区域 周围留下大量采样,同样引起不必要的虚拟碰撞; RFA 除了在极值挖掘区域分配大量采样之外,在其 他探索区域的采样相对匀称,以避免探索过程中的 虚拟碰撞.

6 结论与展望

本文不仅发现了智能优化算法中的虚拟碰撞 问题,还通过仿照植物生长特点,提出了能有效避 免该问题的雨林算法 (RFA).首先,雨林算法逐级分 布样本点,让新生采样填充当前采样空白,以保持 前后不同时段采样点的位置关系,进而避免不必要 的虚拟碰撞;其次,雨林算法以人工树为单元,树与 枝干都拥有自身的伸展范围,以防止同一代采样点 之间的虚拟碰撞;最后,雨林算法以不同范围和密 度的采样点群为执行单元,根据信息反馈调节均匀 与非均匀采样,从而实现探索与挖掘的合理权衡. 这些均赋予 RFA 特殊的机理方式,与以往群体智能 优化算法不同.

实验结果已经表明,雨林算法在解决非凸优化 问题方面,具有明显的优势,它不仅在寻优速度与 准确度两个方面都有突出表现,而且还更加适合 解决更广泛、更复杂的实际寻优问题.然而,关于 这一方法的研究才刚刚开始,还需要大量工作来改 进、检验该算法的效果.例如,在算法的动态方程 设计上,并不需要拘泥于本文所提出的计算公式, 还可以尝试运用其它算子来代替,只要能够满足植



图 18 各算法在标称函数中的采样分布

物优秀的生长特点,都有可能改进雨林算法的性能; 在算法的迭代学习因子的选择上,本文并未给出严 格要求,可以尝试选用不同的参数或者在不同迭代 环节采用不同的学习因子,来试探这一参数对算法 影响的程度和灵敏度;在不同算法的结合方面,可 以尝试与 GA, PSO 以及 ABC(人工蜂群算法)^[33]等 优秀算法的寻优方式进行交叉互补.

作为今后的一个研究方面,可以针对不同具体 类型的寻优问题,寻找雨林算法的最佳参数匹配,

- Beni G, Wang J 1989 Proceedings of NATO Advanced Workshop on Robots and Biological Systems Tuscany, Italy, June 26–30, 1989 p703
- [2] Engelbrecht A, Li X, Middendorf M, Gambardella L M 2009 IEEE Transactions on Evolutionary Computation 13 677
- [3] Smith A E 2000 IEEE Transactions on Evolutionary Computation 4 192
- [4] Zu Y X, Zhou J, Zeng C C 2010 Chin. Phys. B 19 119501
- [5] Wang T T, Li W L, Chen Z H, Miao L 2010 Chin. Phys. B 19 76401
- [6] Gao F, Li Z Q, Tong H Q 2008 Chin. Phys. B 17 1196
- [7] Zhao Z J, Zheng S L, Xu C Y, Kong X Z 2007 Chin. Phys. 16 1619
- [8] Liu X M, Li Y H 2005 Chin. Phys. Lett. 22 1927
- [9] Zhu S F, Liu F, Chai Z Y, Qi Y T, Wu J S 2012 Acta Phys. Sin. 61 96401 (in Chinese) [朱思峰, 刘芳, 柴争义, 戚玉涛, 吴建设 2012 物 理学报 61 96401]
- [10] Kennedy J, Eberhart R 1995 Proceedings of IEEE International Conference on Neural Networks Perth, WA, November 27–December 01, 1995 p1942
- [11] Guo Y C, Hu L L, Ding Y 2012 Acta Phys. Sin. 61 54304 (in Chinese) [郭业才, 胡苓苓, 丁锐 2012 物理学报 61 54304]
- [12] Wang D F, Han P 2006 Acta Phys. Sin. 55 1644 [王东风, 韩璞 2006 物理学报 55 1644]
- [13] Gao F, Tong H Q 2006 Acta Phys. Sin. 55 577 [高飞, 童恒庆 2006 物 理学报 55 577]
- [14] Chen W N, Zhang J, Lin Y, Chen N, Zhan Z H, Chung H, Li Y, Shi Y 2012 IEEE Transactions on Evolutionary Computation 17 241
- [15] Blackwell T 2012 IEEE Transactions on Evolutionary Computation 16 354
- [16] Li X, Yao X 2012 IEEE Transactions on Evolutionary Computation 16 210

以提高雨林算法的解决实际问题的能力.除此之外, 还有一些特殊的优化领域可供雨林算法尝试,其中 包括离散优化(组合优化)、动态优化、多目标优化 等;另外,针对高维优化问题,如何选择均匀采样方 式也是下一步需要深入研究的问题.

感谢感谢大连理工大学刘涛教授和李琦讲师的讨论; 感谢华北水利水电学院张静春老师的鼓励;感谢大连理工 大学马海丰博士与辽宁石油化工大学刘宣宇老师的指点; 感谢大连理工大学韩瑜博士和许光伟博士的支持.

- [17] Zhan Z H, Zhang J, Li Y, Shi Y H 2011 IEEE Transactions on Evolutionary Computation 15 832
- [18] van den Bergh F, Engelbrecht A P 2004 IEEE Transactions on Evolutionary Computation 8 225
- [19] Li X 2010 IEEE Transactions on Evolutionary Computation 14 150
- [20] Shi Y, Eberhart R C 1998 Proceedings of Evolutionary Programming San Diego, California, USA, March 25–27, 1998 p591
- [21] Trelea I C 2003 Information Processing Letters 85 317
- [22] Montes De Oca M A, Stutzle T, Birattari M, Dorigo M 2009 IEEE Transactions on Evolutionary Computation 13 1120
- [23] Poli R 2008 Journal of Artificial Evolution and Applications 2008 1
- [24] Iqbal M, Montes De Oca M A 2006 Proceedings of the fifth international workshop on ant colony optimization and swarm intelligence Brussels, Belgium, September 4–7, 2006 p72
- [25] Xie X F, Zhang W J, Yang Z L 2002 IEEE 2002 International Conference on Communications, Circuits and Systems and West Sino Expositions Chengdu, China, June 29–July 1, 2002 p1170
- [26] Zhang J, Hung H S, Lo W L 2007 IEEE Transactions on Evolutionary Computation 11 326
- [27] Naznin F, Sarker R, Essam D 2012 IEEE Transactions on Evolutionary Computation 16 615
- [28] Poli R, Kennedy J, Blackwell T 2007 Swarm Intelligence Journal 1 33
- [29] Poli R 2009 IEEE Transactions on Evolutionary Computation 13 712
- [30] Macnish C 2007 Connection Science 19 361
- [31] Yang Q, Ding S C 2007 Computer Engineering and Applications 43 80
- [32] Ronkkonen J, Li X D, Kyrki V, Lampinen J 2011 Soft Computing 15 1689
- [33] Vural R A, Yildirim T, Kadioglu T, Basargan A 2012 IEEE Transactions on Evolutionary Computation 16 135

Pseudo-collision in swarm optimization algorithm and solution: rain forest algorithm^{*}

Gao Wei-Shang¹⁾ Shao Cheng¹⁾²⁾ Gao Qin^{1)†}

(School of Control Science and Engineering, Dalian University of Technology, Dalian 116024, China)
 (Institute of Adanced Control Technology, Dalian University of Technology, Dalian 116024, China)
 (Received 4 January 2013; revised manuscript received 2 July 2013)

Abstract

Pseudo-collision (Pc) as a common but neglected phenomenon in swarm optimization algorithm is revealed in this paper. Mechanism analysis on the inevitability of Pc indicates that both the lack of relation among samples and the unconstrained behavior of sampling are the inherent character of agent operation causing Pc in state-of-the-art swarm algorithms such as genetic algorithm (GA) and particle swarm optimization (PSO). Based on the result of mechanism analysis, a novel partition management and classification sampling strategy is proposed to reduce Pc. In addition, both uniform and non-uniform principles are designed to facilitate the trade-off between exploration and exploitation during optimization. Rain forest algorithm (RFA), of which the evolution mechanism is identical with the above strategy and the principles, is proposed in this paper. By examining the rapidity, accuraty, and generalization capability across six benchmark nonconvex functions, RFA is found to be competitive with or even superior to GA and PSO in dealing with complex multi-peak optimization.

Keywords: ptimization algorithm, swarm intelligence, evolutionary computation, computational intelligence

PACS: 02.60.Pn, 87.55.kd, 89.20.Ff, 07.05.Mh

DOI: 10.7498/aps.62.190202

^{*} Project supported by the National Natural Science Foundation of China (Grant No. 61074020).

[†] Corresponding author. E-mail: onlygaoqin@gmail.com