

关于智能优化方法的集聚性与弥散性问题

陈 杰,辛 斌,窦丽华
(北京理工大学 信息科学技术学院,北京 100081)

摘 要:在简要叙述智能优化方法中机制产生的原理和方式的基础上,引入了智能优化算法所应具有 2 种基本属性——集聚性和弥散性.描述了二者与算法收敛性的关系,指出了二者对于分析和构造算法的重要性,并结合实例进行了分析.最后根据算法的集聚性与弥散性,从算法群体进化角度研究了算法中的机制融合方法并结合实例进行了说明.
关键词:智能优化方法;集聚性与弥散性;机制融合;算法进化
中图分类号:TP18 **文献标识码:**A **文章编号:**1673-4785(2007)02-0048-09

Centralization and decentralization of intelligent optimization

CHEN Jie ,XIN Bin ,DOU Li-hua
(School of Information Science and Technology , Beijing Institute of Technology , Beijing 100081 , China)

Abstract :On the basis of a brief analysis of principles and means for the generation of mechanisms in intelligent optimization , centralization and decentralization , that are basic properties of intelligent optimization , are introduced. The relationship between these two properties and convergence is described. The significance of these two properties to analysis and construction of algorithms is proposed. Finally , using an example based on the centralization and decentralization of intelligent optimization , the mechanism combination of algorithm is explored from the point of view of population evolution. The practical examples are given.
Key words intelligent optimization ; centralization and decentralization ; mechanism combination ; algorithm evolution

随着 20 世纪 80 年代计算智能的兴起,智能优化方法作为优化方法的一个新的分支得到了飞速发展.目前关于智能优化方法的定义尚无明确的结论,但是涉及自然机理和生物智能的各种“模拟”型优化方法大多属于智能优化方法的研究范畴,这些方法包括模拟退火算法(SA)^[1]、遗传算法(GA)^[2]、免疫算法(IA)^[3]、蚁群算法(ACO)^[4]、粒子群算法(PSO)^[5]、思维进化算法^[6]、差分进化算法^[7]等,这些基本方法源于不同的思想,性能上也各有千秋.关于它们的基本理论研究包括稳定性、收敛性和快速性等,不同的学者们从马尔可夫链^[8-9]、压缩映射定理^[10]等角度对这些算法进行了收敛性分析,并对不

收敛的原始算法^[9-11]做出改进使其全局收敛或局部收敛.其中文献[12-17]对 SA 进行了一系列改进;文献[18-27]从不同角度出发对 GA 进行了各种改进,具体的改进方式如小生境技术^[18-20]、编码方式^[21]、种群规模控制^[22]、单亲遗传^[23]、引入混沌机制^[24]、多种群并行计算^[25]、结合量子计算^[26]等;文献[27-32]也从相似的角度对 PSO 进行了改进,其中包括缩放策略^[27-28]、引入选择算子^[29]、多种群协同^[30]、参数时变控制^[31]等.文献[32-33]则对 DE 进行了改进.改进的方法各式各样,其中具有代表性的一种是多机制协调方法(混合型方法),相应的改进型算法包括 GASA^[34]、GAPSO^[35]、SAPSO^[36]、IA GA^[37]等.虽然各种算法自身的性质都得到了较好的研究,但是目前缺乏统一性的理论来解释具有何种特征的自然过程或现象可以借鉴从而产

收稿日期:2006-10-13.
基金项目:国家自然科学基金资助项目(60374069)

生新的性能优异的优化算法,以及怎样才能更好更快地向自然学习、向环境学习。从算法的集聚性与弥散性出发来分析和理解各种算法可以得到较为直观的认识,有助于吸取自然界中蕴含的各种优化机理来构造新型算法。另外,作为智能优化方法研究方向的共性规律,机制融合成为了一种趋势和规律。所以研究新机制产生方式的意义除了有利于产生新的思想方法外,还有助于迅速提高已有算法的性能,产生性能优异的混合算法,这实质上是一个优化算法的优化或进化问题。

1 智能优化方法中的机制产生

1.1 寻优基本原理

1) 全局收敛性:由遍历性保证。算法的全局收敛性针对任意可寻优对象或函数而言,对象和函数的多样性和复杂性使得算法只有保证具有可以遍历所有点的能力时才能够确保随着算法的进行可以找到全局最优值。

2) 收敛性与快速性:分别由搜索空间的压缩及压缩效率保证。搜索必定具有未知性,否则搜索失去意义。好的算法能够相对迅速地定位到最优值所在的区域,缩小搜索范围,减少在非最优点上的时间耗费。在最优点位于压缩区域的前提下,搜索区域压缩得越小,算法的收敛速度越快,但是由于对象的复杂性和未知性,使得压缩不能保证前提成立,所以压缩过大反而容易丢失最优点。

3) 矛盾原理:遍历性与快速性是一对矛盾。算法不具有遍历性就无法从理论上保证算法的全局收敛性;不具有快速性,实用价值就会大大降低,尤其是在求解复杂非线性问题时。因此完善的算法中应至少能够分离出2种机制,分别保证遍历性和快速性。

1.2 拟物与仿生

纵观各种现代最优化方法不难发现它们的思想大多来源于自然规律,自然界中存在很多自主优化的现象,挖掘其隐含的规律可以在算法中引进新的机制,对于研究最优化问题具有重要意义。以观察和思考为主要方式挖掘某种自然现象与优化问题的内在联系,找到它们之间的相似性与联系,促进了各种新思想方法的产生。仿生包括模仿个体智能或模仿群体智能2种基本方式。个体智能的模仿,如模仿人,从人搜索目标的方法中挖掘规律;群体智能的模仿,如蚁群算法和粒子群算法分别是对蚂蚁和鸟类群体的活动行为进行了简单的模拟,从中提取出优

化的机制形成新的思想方法。ACO和PSO都是对群体行为的模仿,而另一种群体演化方法——遗传算法则是对群体演化过程的模拟。拟物的典型代表是模拟退火方法,它是一种对自然界中的系统演化规律进行模拟的方法。

2 集聚性与弥散性的定义与分析

2.1 集聚性与弥散性的定义

设 x_1, x_2, \dots, x_N 为算法每次迭代产生的 N 个个体, N 表示每一代的个体数目,固定或可变。设 \bar{x} 和 $\sigma^2(t)$ 分别表示群体的平均位置和位置方差,表示如下:

$$\bar{x} = \frac{1}{N(t)} \sum_{i=1}^{N(t)} x_i(t), \quad (1)$$
$$\sigma^2(t) = \frac{1}{N(t)} \sum_{i=1}^{N(t)} [x_i(t) - \bar{x}]^2.$$

算法的集聚性与弥散性可以基于群体的统计特性定义。

1) 集聚性:群体的位置方差 $\sigma^2(t)$ 随时间递减的性质称为集聚性。这是一种由某种引力场的作用使位于场中的粒子受到引力作用而表现出的向群体中心聚集的性质,它的直接表现是大多数个体到群体中心的距离随时间增长呈现出缩小的趋势,从而导致局部空间粒子密集。它的本质是引力作用。

2) 弥散性:群体的位置方差 $\sigma^2(t)$ 随时间递增的性质称为弥散性。这是一种由某种斥力场的作用使位于场中的粒子受到斥力作用而表现出的群体离心扩张的性质,它的直接表现是大多数个体到群体中心的距离随时间增长呈现出增长的趋势,从而导致空间中粒子稀疏。

由于集聚性与弥散性强调的都是一种单调演化,所以并未包含所有可能的演化模式。由集聚性的定义可知集聚性过程的方差极限存在,但是极限不一定等于零。特别地,当 $\lim_{t \rightarrow \infty} \sigma^2(t) = 0$ 时,称相应的集聚性为绝对集聚性。弥散性过程的方差极限有可能存在,当方差极限存在时称其为有界弥散性,否则为无界弥散性。较为复杂的情况是非单调情况,这种情况中存在引力和斥力2种作用力,二者此消彼长共同控制着过程的演化。对于这种情形,由系统的初态和末态可以判断演化到当前时刻2种作用的强弱关系。如果末态方差比初态方差小,则说明在引斥力的较量中,引力占有优势,相反则斥力占有优势。方差极限不存在的演化过程为弥散性主导过程。方差极限为零的演化过程称为绝对集聚性主导过

程.需要补充的是,在场不存在(即“零场”)的情况下,粒子彼此独立,无相互作用,所以粒子群中的个体在不受限空间中的运动也会呈现出发散的趋势.例如随机运动是弥散性的一种体现方式,也是随机优化算法相比于大多数确定性方法可能具有全局收敛性的根本原因.

由于引力和斥力的形式多样,所以从形式角度出发为二者做统一的定量分析比较困难.为了形成较为直观的理解,后面将以“万有引力”为例对集聚性与弥散性进行分析.

2.2 集聚性和弥散性与寻优算法的关系

定理 任何算法实现全局优化的一个充要条件为:至少存在一个个体 $x_i(t)$, 它与全局最优位置 x^* 组成的二元群体 $\{x_i(t_k), x^*\}$ 在演化中是一个绝对集聚性主导过程.

证明:由绝对集聚性主导过程的定义可知:

$$\lim_{t \rightarrow \infty} (t) = 0 \Leftrightarrow \lim_{t \rightarrow \infty} \frac{1}{4} (x_i(t) - x^*)^2 = 0 \Leftrightarrow \lim_{t \rightarrow \infty} x_i(t) = x^*.$$

需要说明的是,优化的最终结果往往取最后一代群体中最优个体对应的取值,所以只要存在一个个体(不管具体是哪一个)满足趋于全局最优点的条件,就足以保证算法收敛到全局最优点.如果任何个体都不能趋于全局最优点,则算法显然不能实现全局收敛.从本质上讲,这个定理是全局收敛性的另一种描述,但是它从集聚性角度指出了算法全局收敛的重要原则——“与最优点的位置建立并保持直接的关系”,这一原则称为保优原则(也称为基本原则).如果不采用这一原则,算法将无法保证全局收敛性或局部收敛性.因为当不采用此原则时,在比较非最优个体和全局最优个体并进行保留时,接受最优个体的概率小于1(设第 n 次比较时最优保留概率为 p_n),即使演化过程中某一次比较时最优个体被确定性地保留下来,后续的演化也会以一定的概率将其随机淘汰掉,这是自然进化中体现出的规律,但是在优化中给算法带来的却是不利的影响.这是因为,算法最终找到最优点的概率可以表示为

$$P = \lim_{n \rightarrow \infty} p_n(n). \quad (3)$$

式中: p_n 为第 n 次比较时群体中全局最优个体的比例.只有 $\lim_{n \rightarrow \infty} p_n(n) = 1$ 和 $\lim_{n \rightarrow \infty} p_n(n) = 1$ 同时成立,才能保证算法实现全局最优化.对于大多数非保优算法而言, $\lim_{n \rightarrow \infty} p_n(n) < 1$, 所以有 $P < 1$, 因而无法保证算法实现全局最优化.

从算法的实际操作角度讲,算法经过有限时间截断后,全局优化性能会有明显的差别,向全局最优点收敛速度快的算法性能更优异.集聚性过强的算法往往会因为空间探索不足而陷入局部极值甚至更糟,所以弥散性在算法的构造中也具有重要意义,因为它的存在使算法具有较强的空间探索能力从而摆脱局部极值,这也是很多学者对优化算法改进的一个主要方式^[27-28].

事实上,无论是仿生还是拟物,它们都有一个共同特点——模仿的对象具有弥散性或集聚性.具有弥散性质的对象或过程往往能与算法的遍历性(全局优化性能)要求建立对应关系,而具有集聚性质的对象或过程则往往能与算法的收敛性(局部收敛性)要求建立对应关系(实际上由定义可知集聚性的内涵比收敛性更广).完善的算法在结构体制中同时具有弥散性与集聚性,将这2种矛盾的机制融合,并在一定程度上使二者达到一定的平衡.以模拟退火算法为例,保优策略具有集聚性,它引导分析集聚到较优点所在的局部区域中,而温控策略和状态接受机制则具有弥散性,把分析分散到其他区域中,减小遗漏最优点的概率.从自然现象中探求有助于优化的机理,就是根据寻优的基本原理从自然界中具有弥散性或集聚性的现象中找到与寻优过程相似的特征、挖掘规律、提取机制.一般而言,只具有集聚性的算法不一定能收敛到全局最优点或局部最优点,但是引入一定的弥散性后都能在一定程度上改善其全局优化性能.而且自然界中具有集聚性或弥散性的过程或现象都可以经过改造后用于优化算法的改进或直接构造新型算法,如最近有学者分别提出了基于野草繁殖扩张的优化算法^[38]和基于宇宙爆炸-坍塌的优化算法^[39],尤其是文献^[39]中的爆炸和坍塌子过程可以分别体现出弥散性与集聚性的意义和作用.

2.3 集聚性与弥散性的实例分析

下面以一个典型的具有集聚性和弥散性特征的过程为例分析“集聚性和弥散性”与寻优原理的对应关系.假设二维平面上有 n 个具有质量且体积可忽略的粒子(可作质点研究),只受彼此间的万有引力作用,给定初始状态,包括初速度和初始位移,求经过时间 t 后各粒子的位置.

简单情况下研究2个质点的运动规律,系统可以由下列方程表示:

$$s_1(t) = s_{01} + \int_0^t v_{01} dt + \int_0^t \int_0^t \frac{Gm_2}{s(t)^3} s(t) dt dt, \quad (4)$$

$$s_2(t) = s_{02} + \int_0^t v_{02} dt + \int_0^t \frac{Gm_1 - s(t)}{s(t)^3} dt, \quad (5)$$
$$s(t) = s_2(t) - s_1(t). \quad (6)$$

式中: t 为时间; v_{01} 、 v_{02} 为第 1 个和第 2 个粒子的初速度; s_{01} 、 s_{02} 为第 1 个和第 2 个粒子的初始位移; s_1 、 s_2 为第 1 个和第 2 个粒子的位移; s 为两粒子的位移差; G 为万有引力常数; m_1 、 m_2 为第 1 个和第 2 个粒子的质量.

二者组成的系统可以由图 1 表示.




图 1 两粒子运动规律示意图

Fig. 1 Sketch map of movement law of two particles

该系统主要由二阶积分器和引力计算器(主要完成粒子间相对位移和加速度的计算)组成,是一个典型的双环反馈系统.当初始条件确定后,系统按照固定的轨迹运行.系统运行的状态由初始状态唯一决定.将粒子数扩展到 n 个,系统的框图如图 2 所示.




图 2 粒子群运动的控制结构

Fig. 2 Structure of movement control of particles

这是一个以引力计算器为核心构成的星形结构.引力计算器接受来自各子系统提供的信息,完成数据的交互与处理,并将加速度反馈给各子系统.各子系统都是单环反馈系统.该结构的复杂性主要由交互性造成的高度耦合引起,这种交互使系统的整体性能由其核心——引力计算器决定,只要各粒子初始状态不超越引力束缚的边界,尽管单个粒子的运动可能非常复杂,但由于引力场的存在,群体随时

间的演化一定会体现出集聚特性,当粒子数相对较多时,系统的外在表现往往是个体的无规则运动和随时间增长显现出的集聚特征.

将引力计算器去掉,则各子系统独立,粒子维持原速度状态运动.而将引力计算器改为斥力计算器,则系统的外在表现为随时间增长显现出的弥散特征,这种弥散性使粒子能够扩散到更为广阔的空间区域中. PSO 方法可以从这个模型中得到一定的解释,其核心的迭代公式为

$$v_{id}^{k+1} = w \cdot v_{id}^k + c_1 \cdot \text{rand}_{id} \cdot (p_{gd}^k - x_{id}^k) +$$
$$c_2 \cdot \text{rand}_{pd} \cdot (p_{id}^k - x_{id}^k), \quad (7)$$
$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1}. \quad (8)$$

式中: k 为迭代次数; w 为惯性权值,一般取值范围为 $(-1, 1)$; c_1 、 c_2 为加速度因子, Clerk^[55] 建议取值为 0.72, rand_{id} 和 rand_{gd} $(0, 1)$ 内的随机数; p_{gd}^k 为第 k 次迭代时总体最优位置的第 d 维分量; p_{id}^k 为第 k 次迭代时第 i 个粒子运动历史中自身的最优位置的第 d 维分量; x_{id}^k 为第 k 次迭代时第 i 个粒子位置的第 d 维分量; v_{id}^k 为第 k 次迭代时第 i 个粒子速度的第 d 维量.

与多粒子运动模型相同的是, PSO 模型的位移也由速度累加(积分)求得,而速度的变化也与相对位移有关,但是相对位移的参考点有 2 个,一是群最优点 p_{gd} ,二是各粒子运动过程中的最优点 p_{id} . 所以 PSO 模型与上述多粒子运动模型的主要区别在于 PSO 模型中系统结构的中心不是力场 $a(t)$,而是群最优点,同时各粒子运动过程中的最优点也参与控制.




图 3 标准 PSO 引力示意图

Fig. 3 Sketch map of gravitation in PSO

如图 3 所示,图中最右边的点是当前群最优点,与其相连的点是上一代的群最优点,其连接线表示的是系统演化的主方向.小圆圈表示各粒子运动过程中的最优点.群最优点之外的其他点同时受到群

最优点和自身运动过程中的最优点产生的 2 种“场”的“引力作用”,所以当速度控制在“引力束缚作用”之内时,系统演化的最终结果会使各粒子向群最优点集聚,从而使该算法具有收敛性.同时容易看到的是:尽管随机数的引入使 PSO 有一定的弥散性,但是基于式(4)、(5)的 PSO 缺乏一种充足的弥散机制,在某些情况中会陷入局部极值从而难于实现全局最优.在 PSO 中加入一种可产生遍历性的弥散机制后,就可以保证 PSO 的全局收敛性,如 BPSO^[27].更为简单的方法是将全局随机搜索方法与 PSO 混合,则随机搜索产生的子序列可以保证算法总体的全局收敛性^[40],而 PSO 则相当于局部搜索方法,接受全局随机搜索方法提供的最优信息,由于 PSO 知识利用能力较强,所以令其负责较小范围的快速搜索.从无限迭代的角度讲,全局随机搜索法与任何其他优化方法结合都可以保证算法的全局收敛性,但是由于全局随机搜索方法收敛缓慢,所以混合算法的收敛速度往往取决于与全局随机搜索法结合的另外一种方法.

3 智能优化方法中的机制融合方法

3.1 机制融合的原理

在 GA 方法产生后产生了 GASA 方法^[34],将 2 种方法的机制有机地结合起来. PSO 提出后又产生了 SAPSO^[36]、GAPSO^[35],在 COA^[41]的基础上又产生了 COASA^[42]、COAGA^[43]、COAPSO^[44]等混合型算法. DE 与 SA、ACO、PSO 结合分别产生了 SADE^[45]、ACODE^[46]、PSODE^[47],IA 与 GA 结合产生了 IAGA^[37],量子计算(QC)与 GA、PSO 结合产生了 QGA^[48]、QPSO^[49],此外还有 SA 与单纯形法^[50]、爬山法^[51]等算法的结合,GA 与模式搜索法^[52]结合,DE 与 Powell 方向集法的结合^[53],在两两结合之外还出现了更多方法的结合,如 SA 与 TS(禁忌搜索)、梯度下降法三者的结合^[54].各种新算法的提出呈现出一个共同规律:它们都迅速促进了新的混合型算法的产生,而且混合型算法往往比原始算法具有更好的性能.把算法与生物个体建立对应关系,算法中的机制与基因建立对应关系,各种算法组合成的算法群体也呈现出“种群进化”的规律.

优化中的机制融合是指在同一种方法中以串行、并行或嵌入^[34]的方式使用多种方法的机制,通过交互协调寻优.这种方法与遗传算法中的交叉操作相似.目前没有理论能够证明 2 种不同算法的机

制融合一定能产生比 2 种算法更好的新算法,生物种群中对应的进化规律正是如此.但是从协调学的角度分析,各种不同算法往往都有独立的思想体系和有别于其他方法的优缺点,研究不同算法机制融合的目的在于发挥各种算法独有的优势,使各种算法机制协调、优势互补,进而获得一种“组合优势”.

研究机制融合的方法关键是根据寻优的基本原理找到不同算法的优势所在和缺陷所在.找到优势产生的本源,利用一种方法的优势去弥补另一种方法的缺陷,反之亦然.根据算法的集聚性与弥散性原理以及算法进化原理,机制融合应当遵循互补原则,如果一种算法具有较好的弥散性而集聚性(快速性)不够好(如标准模拟退火算法、标准混沌算法、蒙特卡罗方法等),收敛速度较慢,则可以与集聚性较好的算法(如搜索空间渐缩法、粒子群算法等)融合,反之亦然.

3.2 机制融合的方法

机制融合主要有 2 种方法:一是与纯数学理论结合,二是与其他智能优化方法中的机制融合.第一种方法在于利用优化问题求解的数学理论,如传统的优化方法虽然不适于求解全局最优化问题,但是大多数全局最优化问题经过一定分析后最终可以转化为局部优化问题,这样就可以发挥传统优化方法在收敛速度方面的优势.下面以 GA 和 PSO 的融合为例分析算法融合的原理与方法.融合类似于一种化学反应,反应生成新的结构,新结构分为并行、串行和嵌入 3 种基本类型.相比而言,PSO 的集聚性较强,而 GA 的弥散性较强,融合过程如图 4 所示.

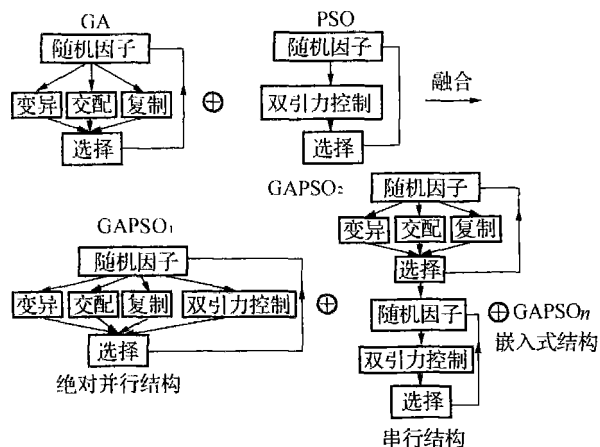


图 4 GA 与 PSO 的融合示意图

Fig. 4 Sketch map of the combination of GA and PSO

其中,PSO 算法和 GA 算法以及新的算法均用机制及其流程转换关系表示(省去了控制部分).嵌入式结构未在图中给出. $GAPSO_1$ 型算法是一种绝对并行结构,实际上由于单台计算机执行能力的限制,这种算法目前只适于网络分布计算,而一般采用的是一种相对并行结构,即演化中交替地执行 GA 和 PSO.

在融合后产生的新算法的主体结构中,控制单元综合协调多种集聚和弥散过程,而且它与集聚过程以及弥散过程的信息交互量增大,控制依据的可靠性增强,并且增强了多个过程(方法)的交互性,降低了任何一种方法的盲目性,不同的算法之间产生了互补效应,因而有利于算法整体性能的提高.图 5 具体说明了算法间互补的原理,该图表示采用相对并行结构的算法分析图中所示函数的最小点.如图中左上方所示,PSO 的集聚性较强,分析点比 GA 更快地集聚,而 GA 的弥散性较强,分析点相对分

散,保持了相对较好的弥散性,它的弥散性使其可以探索到更优的点(如图中左下方所示),同时对下一步的 PSO 进程进行指导,使之迅速集中到当前最优值所在的局部区域进行搜索分析(如图右上方所示).同时 PSO 的集聚性也在引导 GA 的搜索过程,使其相对较快地集聚. GA 的弥散性与 PSO 的集聚性之间产生了一种互补优势,使其相互促进,提高了算法的整体性能.其他算法之间融合的方法和原理与此相似,不同之处在于各种算法的内部机制有所不同.需要补充的是,确定性算法一般只适于求解确定性问题而且要求研究对象有较好的性质,如连续性、可微性等,其快速性是与“它们利用了对象的特殊性”紧密相关的.所以确定性方法本身不能简单地纳入算法的一般结构中.已有算法通过机制融合可以互相结合生成新的算法.研究的目的在于结合具体的最优化研究方向探求与研究对象匹配的性能更优越的新算法.




图 5 PSO 与 GA 之间的互补效应
Fig. 5 Complementary effect between PSO and GA

4 结束语

最优化算法的发展是一个与生物种群进化相似的演化过程.各种已产生的算法组成了一个算法种群,它们之间通过机制融合等方式进行进化,但是从进化论和信息论角度讲,新的有效算法的产生更有助于种群的进化,它使种群的性能得到突变,并带来更多的有用信息.对应于生物种群进化中的变异与

交配机制,算法改进的 2 种主要方式就是提出新的算法和对已有算法进行机制融合,文中对机制的生成和融合进行了论述与分析,挖掘出算法进化的原理,尤其是算法所应具备的集聚性与弥散性,体现了智能优化方法与所对应的自然现象或过程之间的联系,指出了可以用于优化的自然现象的基本特征,对于新算法的产生具有指导意义.集聚性与弥散性在智能优化方法的理论统一方面的具体应用还有待进

一步研究.


参考文献:

- [1] METROPOLIS N, ROSENBLUTH A, ROSENBLUTH M, et al. Equation of state calculations by fast computing machines[J]. Journal of Chemical Physics, 1953, 21: 1087 - 1092.
- [2] HOLLAND J H. Adaptation in natural and artificial systems [M]. Ann Arbor: The University of Michigan Press, 1975.
- [3] 黄席樾, 张著洪, 何传江, 等. 现代智能算法理论及应用 [M]. 北京: 科学出版社, 2005.
- [4] COLONI A, DORIGO M, MANIEZZO V. Distributed optimization by ant colonies[A]. Proceeding of 1st European Conference of Artificial Life [C]. Paris, France, 1991.
- [5] KENNEDY J, EBERHART R. Particle swarm optimization[A]. Proceeding of IEEE International Conference on Neural Networks[C]. Piscataway, NJ, 1995.
- [6] SUN Chengyi, SUN Yan, LI Junwei. Mind evolution based machine learning: framework and the implementation [A]. Proceedings of the IEEE International Conference on Intelligent Engineering System[C]. Vienna, Austria, 1998.
- [7] STORN R, PRICE K. Differential evolution—a simple and efficient adaptive scheme for global optimization over continuous spaces [R]. TR - 95 - 012, ICSI, March, 1995.
- [8] GIDAS B. Nonstationary Markov chains and convergence of the annealing algorithm [J]. Journal of Statistical Physics, 1985, 39:73 - 131.
- [9] RUDOLPH G. Convergence analysis of canonical genetic algorithms[J]. IEEE Transactions on Neural Networks, 1994, 5(1): 96 - 101.
- [10] MICHALEWICZ Z. Genetic algorithms + data structure = evolution programs[M]. New York: Springer-Verlag, 1996.
- [11] VAN DEN BERGH F. An analysis of particle swarm optimizers[D]. Pretoria: University of Pretoria, 2002.
- [12] AZIZI N, ZOLFA GHARI S. Adaptive temperature control for simulated annealing: a comparative study[J]. Computers & Operations Research, 2004, 31: 2439 - 2451.
- [13] TSALLIS C, STARIOLO D A. Generalized simulated annealing[J]. Physica A, 1996, 233: 395 - 406.
- [14] YE Hong, LIN Zhiping. Speed-up simulated annealing by parallel coordinates [J]. European Journal of Operational Research, 2006, 173: 59 - 71.
- [15] TSOULOS I G, LAGARIS I E. GenAnneal: genetically modified simulated annealing [J]. Computer Physics Communication, 2006, 174: 846 - 851.
- [16] WANG Ling, ZHANG Liang. Stochastic optimization using simulated annealing with hypothesis test [J]. Applied Mathematics and Computation, 2006, 174: 1329 - 1342.
- [17] JI Mingjun, JIN Zhihong, TANG Huanwen. An improved simulated annealing for solving the linear constrained optimization problems[J]. Applied Mathematics and Computation, 2006, 183(1): 251 - 259.
- [18] CAVICCHIO D J. Adaptive search using simulated evolution[D]. Michigan: University of Michigan, 1970.
- [19] DE JONG K A. An analysis of the behavior of a class of genetic adaptive system [D]. Michigan: University of Michigan, 1975.
- [20] GOLDBERG D E, RICHARDSON J. Genetic algorithms with sharing for multimodal function optimization [A]. Proceedings of the 2nd International Conference on Genetic Algorithms [C]. Hillsdale, NJ: Lawrence Erlbaum, 1987.
- [21] GOLDBERG D E. Real-coded genetic algorithms, virtual alphabets and blocking [R]. University of Illinois at Urbana-Champaign, Technical Report No. 90001, 1990.
- [22] ARABAS J, MICHALEWICZ Z, MULARLA J. GaVaPS—a genetic algorithm with varying population size [A]. Proceedings of the 1st IEEE International Conference on Evolutionary Computation[C]. [s.l.], 1994.
- [23] 李茂军, 童调生. 单亲遗传算法及其全局收敛性分析 [J]. 自动化学报, 1999, 25(1): 69 - 73.
- LI Maojun, TONG Tiaosheng. A partheno-genetic algorithm and analysis on its global convergence[J]. Acta Automatica Sinica, 1999, 25(1): 69 - 73.
- [24] 骆晨钟, 邵惠鹤. 采用混沌变异的进化算法[J]. 控制与决策, 2000, 15(5): 557 - 560.
- LUO Chenzhong, SHAO Huihe. Evolutionary algo-

- rithms with chaotic mutations[J]. Control and Decision, 2000, 15(5):557 - 560.
- [25] 巩敦卫,孙晓燕. 变搜索区域多种群遗传算法[J]. 控制理论与应用, 2006, 23(2):256 - 260.
- GONG Dunwei, SUN Xiaoyan. Multi-population genetic algorithms with variational search areas[J]. Control Theory and Applications, 2006, 23(2):256 - 260.
- [26] HAN K H, KIM J H. Genetic quantum algorithm and its application to combinatorial optimization problems [A]. Proceedings of the IEEE Conference on Evolutionary Computation, Piscataway[C]. 2000.
- [27] PAN Feng, CHEN Jie, CAI Tao, et al. Stability, convergence of balloon particle swarm optimizer and its application[A]. Proceedings of the 16th IFAC Congress [C]. Prague, Czech, 2005.
- [28] RIGET J, VESTERSTROEM J S. A diversity-guided particle swarm optimizer-the ARPSO[R]. No. 2002 - 02, Department of Computer Science, University of Aarhus, EVALife, 2002.
- [29] ANGELINE P J. Using selection to improve particle swarm optimization[A]. Proceedings of IEEE Conference on Evolutionary Computation [C]. Anchorage, USA, 1998.
- [30] BERGH F V D, ENGELBRECHT A P. A cooperative approach to particle swarm optimization [J]. IEEE Transactions on Evolutionary Computation, 2004, 8(3):225 - 239.
- [31] RATNAWEERA A, HAL GAMUGE S K, WATSON H C. Self-organizing hierarchical particle swarm optimizer with time-varying acceleration coefficients[J]. IEEE Transactions on Evolutionary Computation, 2004, 8(3):240 - 255.
- [32] TASOULIS D K, PAVLIDIS N G, PLAGIANNAKOS V P, et al. Parallel differential evolution[A]. Proceedings of the CEC04 Congress on Evolutionary Computation [C]. Portland, USA, 2004.
- [33] PAVLIDIS N G, PLAGIANNAKOS V P, TASOULIS D K, et al. Human designed Vs. genetically programmed differential evolution operators[A]. Proceedings of the IEEE Congress on Evolutionary Computation [C]. Vancouver, Canada, 2006.
- [34] 王 凌. 智能优化算法及其应用[M]. 北京:清华大学出版社, 施普林格出版社, 2000.
- [35] 吴晓军, 薛惠锋, 李 强, 等. GA-PSO 混合规划算法[J]. 西北大学学报(自然科学版), 2005, 35(1):39 - 42.
- WU Xiaojun, XUE Huifeng, LI Min, et al. A new programming of mixed genetic algorithm with particle swarm optimization[J]. Journal of Northwest University (Natural Science Edition), 2005, 35(1):39 - 42.
- [36] 王丽芳, 曾建潮. 基于微粒群算法与模拟退火算法的协同进化方法[J]. 自动化学报, 2006, 32(4):630 - 634.
- WANG Lifang, ZENG Jianchao. A cooperative evolutionary algorithm based on particle swarm optimization and simulated annealing algorithm[J]. Acta Automatica Sinica, 2006, 32(4):630 - 634.
- [37] JIAO Licheng, WANG Lei. A novel genetic algorithm based on immunity[J]. IEEE Transactions on System, Man and Cybernetics-Part A: Systems and Humans, 2000, 30(5):552 - 561.
- [38] MEHRABIAN A R, LUCAS C. A novel numerical optimization algorithm inspired from weed colonization [J]. Ecological Informatics, 2006, 1(4):355 - 366.
- [39] EROL O K, EKSIN I. A new optimization method: big bang-big crunch[J]. Advances in Engineering Software, 2006, 37:106 - 111.
- [40] SOLIS F J, WETS R J B. Minimization by random search techniques[J]. Mathematics of Operations Research, 1981, 6(1):19 - 30.
- [41] 李 兵, 蒋蔚孙. 混沌优化方法及其应用[J]. 控制理论与应用, 1997, 14(4):613 - 615.
- LI Bing, JIANG Weisun. Chaos optimization method and its application[J]. Control Theory & Applications, 1997, 14(4):613 - 615.
- [42] JI Mingjun, TANG Huanwen. Application of chaos in simulated annealing [J]. Chaos, Solitons & Fractals, 2004, 21:933 - 941.
- [43] 袁晓辉, 袁艳斌, 王 乘, 等. 一种新型的自适应混沌遗传算法[J]. 电子学报, 2006, 34(4):708 - 712.
- YUAN Xiaohui, YUAN Yanbin, WANG Cheng, et al. A novel self-adaptive chaotic genetic algorithm[J]. Acta Electronica Sinica, 2006, 34(4):708 - 712.
- [44] 杨俊杰, 周建中, 喻 菁, 等. 基于混沌搜索的粒子群优化算法[J]. 计算机工程与应用, 2005, 16:69 - 71.
- YANG Junjie, ZHOU Jianzhong, YU Jing, et al. Par-


- ticle swarm optimization algorithm based on chaos searching[J]. Computer Engineering and Applications, 2005, 16: 69 - 71.
- [45] SCHMIDT H, THIÉRAUF G. A combined heuristic optimization technique [J]. Advances in Engineering Software, 2005, 36:11 - 19.
- [46] CHIOU Jpi, CHANG C-f, SU C-t. Ant Direction hybrid differential evolution for solving large capacitor placement problems[J]. IEEE Transactions on Power System, 2004, 19(4):1794 - 1800.
- [47] ZHANG Wenjun, XIE Xiaofeng. DEPSO: hybrid particle swarm with differential evolution operator[A]. Proceedings of the IEEE International Conference on Systems[C]. Washington, USA, 2003.
- [48] NARAYANAN A, MOORE M. Quantum-inspired genetic algorithm[A]. Proceedings of the IEEE International Conference on Evolutionary Computation [C]. Piscataway, 1996.
- [49] YANG Shuyuan, WANG Min, JIAO Licheng. A quantum particle swarm optimization [A]. Proceedings of CEC2004 Congress on Evolutionary Computation [C]. Portland, USA, 2004.
- [50] KVASNICKA V, POSPICHAL J. A hybrid simplex method and simulated annealing[J]. Chemometrics and Intelligent Laboratory System, 1997, 39:161 - 173.
- [51] LIM A, RODRIGUES B, ZHANG X. A simulated annealing and hill-climbing algorithm for the traveling tournament problem [J]. European Journal of Operational Research, 2006, 174:1459 - 1478.
- [52] PENG Yehui. A hybrid algorithm combining pattern search method and genetic algorithm for bound constrained optimization [J]. Mathematical Theory and Applications, 2005, 25(4):1 - 4.
- [53] XU Xiaoyan, DONG R D. Differential evolution with Powell's direction set method in medical image registration [A]. Proceedings of the IEEE International Symposium on Biomedical Imaging: Macro to Nano [C]. Arlington, USA, 2004.
- [54] SALHI S, QUEEN N M. A hybrid algorithm for identifying global and local minima when optimizing functions with many minima[J]. European Journal of Operational Research, 2004, 155:51 - 67.
- [55] CLERK M, KENNEDY J. The particle swarm: explosion, stability and convergence in a multi-dimensional complex space[J]. IEEE Transactions on Evolutionary Computation, 2002, 6(1):58 - 73.

作者简介:



陈杰,男,1965年生,教授,博士生导师,中国人工智能学会常务理事,中国自动化学会常务理事兼副秘书长,主要研究方向为复杂系统多目标优化与决策、智能控制、约束系统非线性控制、优化方法。获部级科技进步奖10项,完成科研项目20余项,发表学术论文70余篇,出版著作3部。

Email: chenjie@bit.edu.cn.



辛斌,男,1982年生,博士研究生,主要研究方向为计算智能、优化方法、模式识别等。



窦丽华,女,1961年生,教授,博士生导师,中国人工智能学会智能网络分会委员,主要研究方向为模式识别与智能系统。承担国家重点型号装备项目、重点预研项目和基金项目4项,获国防科工委科技进步4项,近几年在核心期刊上发表论文20余篇。