

基于 L_1 范式的粒子群算法群体多样性研究

程 适^{1,2} 史玉回²

(利物浦大学电子与电气工程系 利物浦 英国)¹ (西交利物浦大学电气与电子工程系 苏州 215123)²

摘 要 提出了一种新的基于 L_1 范式的粒子群算法群体多样性定义,这种观测方式可以准确地描述算法运行过程中的信息。首先,通过对比新的观测方式和已有方式,解释了新的观测方式的特点;然后通过实验观测了位置、速度和认知三种群体多样性在算法执行过程中的变化,给出了群体多样性的变化特征。最后讨论了粒子群算法在不同解空间维数、不同粒子群拓扑结构和不同粒子数目时的群体多样性的变化情况。

关键词 演化计算,粒子群优化,群体多样性,位置多样性,速度多样性,认知多样性,范式

中图法分类号 TP301.6 **文献标识码** A

Measurement of PSO Diversity Based on L_1 Norm

CHENG Shi^{1,2} SHI Yu-hui²

(Dept. of Electrical Engineering and Electronics, University of Liverpool, Liverpool, UK)¹

(Dept. of Electrical & Electronic Engineering, Xi'an Jiaotong-Liverpool University, Suzhou 215123, China)²

Abstract A novel PSO population diversity based on norm was defined, which provides useful information of PSO search process. Population diversity based on and norms were analyzed as well as element-wised and dimension-wised PSO diversity. Population diversities of PSO with different number of dimensions, different topology structure, and different population sizes were discussed and tested on benchmark functions.

Keywords Evolutionary computation, Particle swarm optimization, Population diversity, Position diversity, Velocity diversity, Cognitive diversity, Norm

1 引言

粒子群优化(Particle Swarm Optimization, PSO)是一种新的演化计算的方法。这种算法来源于对鸟群觅食过程中协同行为的模拟,在 1995 年由 Eberhart 与 Kennedy 提出^[1,2]。它是一种基于群体协作的随机算法,群体中的每个个体被抽象为一个“粒子”,整个粒子的集合被称为“粒子群”。

在算法中,每一个粒子都代表需要求解的问题在搜索空间中的一个解。这些粒子同时拥有速度和位置的信息,通过粒子之间的相互协同作用,每一个粒子根据经验有侧重地随机动态调整其“飞行”方向和速度大小,使粒子群更有可能地飞向越来越“好”的搜索区域,从而快速找到满足需求且足够好的解^[3,4]。

粒子群优化拥有易于理解、易于实现的特点,且对非线性问题、多峰问题、约束优化问题、多目标优化问题和动态优化问题均具有较强的搜索能力,在科学研究与工程实践中得到了广泛关注^[5-8]。算法基本迭代公式如下所示:

$$v_{ij} = \omega v_{ij} + c_1 \text{rand}() (p_{ij} - x_{ij}) + c_2 \text{rand}() (p_{gj} - x_{ij}) \quad (1)$$

$$x_{ij} = v_{ij} + x_{ij} \quad (2)$$

式(1)表示第 i 个粒子在 j 维度上的运动速度的变化,式(2)表示第 i 个粒子在 j 维度上位置的变化。算法流程如算法 1 所示。为了验证新的观测方式的通用性,本文对不同的解空

间维数,不同的粒子群拓扑结构和不同的种群大小上的多样性变化进行了观测。对于这些不同的粒子群算法参数设置,新的多样性观测方法可以准确地表征粒子群的运行信息。同样地,这种观测方法也可以用于粒子群算法的不同变体。

算法 1 粒子群优化基本流程

1. 对于每个粒子,随机地初始化粒子在每一维的速度和位置
2. While 未找到符合要求的最优解或未达到算法最大迭代次数 do
3. 计算每个粒子的适应度值(fitness values)
4. 比较粒子当前位置与此粒子历史最优位置(p_{best})的适应度值,如果当前位置适应度值优于粒子历史最优位置,则更新此粒子历史最优位置为当前位置
5. 选择当前粒子邻域中拥有最好适应度值的粒子,作为当前粒子的邻域最优值。如果当前粒子的邻域为所有粒子,则邻域最优值称为全局最优值(g_{best}),否则称为局部最优值(l_{best})
6. for 每一个粒子
7. 根据式(1)更新粒子的速度;根据式(2)更新粒子的位置
8. end for
9. end while

影响群智能算法性能的重要因素是算法“探索”(exploration)和“开发”(exploitation)能力的平衡性,而算法的群体多样性(population diversity)是衡量算法探索和开发状态的重要指标。对群体多样性进行观测,多样性在瞬态的值描述了算法当时的运行状态,而多样性值的变化趋势描述了算法的整体求解过程。如何合理地定义群体多样性,正确地表征算

到稿日期:2010-08-28 返修日期:2010-11-30 本文受国家自然科学基金项目(60975080),苏州市科技项目(SYJG0919)资助。

程 适 博士生,主要研究方向为演化计算、粒子群优化、文本分类,E-mail:Shi.Cheng@liverpool.ac.uk;史玉回 教授,主要研究方向为计算智能、粒子群优化、数据挖掘、动态优化。

法执行时粒子群的运动过程,对演化计算有着重要的意义。

本文第2节对已有的不同群体的多样性,包括位置、速度和认知多样性的定义分别进行了介绍,并提出了一种新的多样性观测方式;第3节通过观测在算法执行过程中不同定义方式的群体多样性在多个测试函数上的变化情况,分析了不同定义的群体多样性的优缺点;并将群体多样性观测应用到以下3种情况:求解问题具有不同解空间维数,粒子群拥有不同拓扑结构和粒子群拥有不同粒子数目;最后是对全文的简单总结,并展望了通过直接或间接的方法对多样性进行控制,从而改善算法性能。

2 群体多样性定义

群体多样性提供了群智能算法的运行信息,如何选择合适的观测方式来表征群体多样性,这对了解算法运行信息以及改善算法性能有着重要的意义。群体多样性给出了算法运行时粒子的位置和速度的分布信息,粒子处在“分散”或者“收敛”的阶段。多样性的观测定义都基于距离的度量,而在欧氏空间中,距离的概念与范式息息相关。

在欧氏空间 \mathbb{R}^n 上,范式是一个满足特定性质,由 \mathbb{R}^n 到 \mathbb{R} 上的映射函数。基于不同范式的度量具有等价性^[9]。若 $\|\cdot\|_\alpha$ 和 $\|\cdot\|_\beta$ 是在欧氏空间 \mathbb{R}^n 上的两种范式度量,则存在正常数 c_1 与 c_2 使以下不等式恒成立:

$$c_1 \|x\|_\alpha \leq \|x\|_\beta \leq c_2 \|x\|_\alpha$$

将不同的范式度量应用到粒子群的多样性观测上,观测所得数值间存在着差异,但这些数值拥有相同的变化趋势。对于群体多样性的观测,重要的是如何精确获得多样性变化趋势,而非多样性数值的大小。即不同范式度量对于粒子群算法的群体多样性定义具有等价性。不同范式对计算效率有着很大影响,并随着迭代次数的增大而累加,因此,选取合适的范式对于多样性的测量有着重大意义。

目前粒子群优化的群体多样性的定义都集中于位置多样性、速度多样性和认知多样性,且距离的度量都采用欧式距离,即 L_2 范式^[10-12]。下面将对这3种定义分别进行讨论:设定当前粒子群中粒子数目为 m ,粒子编号为 i ;解空间维度为 n ,维度编号为 j 。

2.1 位置多样性

关于位置多样性的定义,主要有基于粒子个体(element-wise)和基于维度(dimension-wise)两种。基于粒子个体的位置多样性如下所示^[10]:

$$\bar{x} = \frac{1}{m \times n} \sum_{i=1}^m \sum_{j=1}^n x_{ij} \quad (3)$$

$$D_j^p = \frac{1}{m \times n} \sum_{i=1}^m \sum_{j=1}^n (x_{ij} - \bar{x})^2 \quad (4)$$

基于粒子个体的多样性观测将粒子的所有维度视为一个整体,首先求出所有粒子当前位置在所有维度的平均,然后计算所有粒子当前位置与这个均值差的平方,将平方值求和后除以粒子个数和解空间维数,用计算出的结果来表示粒子群当前的位置多样性。

基于粒子个体的定义将粒子在各个维度的位置求和,忽视了不同维度多样性的差异,特别是在极值点各维度数值不同的情况下,难以起到合理表征算法多样性的作用。例如两种简单的情况,假设它们有两个粒子在二维空间运动,当前位

置分别为(1,7)与(7,1),通过式(3)得出 $\bar{x}=4$,通过式(4)得出 $D_j^p=9$;而当两个粒子都处于(1,7)时,依然得到 $\bar{x}=4$ 与 $D_j^p=9$ 。但实际上这两种不同的粒子运行状态的多样性应具有不同的值。

为了表征粒子在不同维度的多样性的差异,可以采用基于维度的位置多样性,其定义如下所示^[10,11]:

$$\bar{x} = \frac{1}{m} \sum_{i=1}^m x_{ij} \quad (5)$$

$$D_j^p = \frac{1}{m} \sqrt{\sum_{i=1}^m (x_{ij} - \bar{x})^2} \quad (6)$$

基于维度的位置多样性定义首先得出所有粒子当前位置在各个维度上的中心 $\bar{x} = [\bar{x}_1, \dots, \bar{x}_j, \dots, \bar{x}_n]$,然后计算粒子在各个维度当前位置与维度中心差的平方,将平方值求和后除以粒子个数,用计算出的结果来表示粒子当前在各个维度上的位置多样性。

基于维度的位置多样性定义可以更清晰地表征算法运行过程中多样性的变化情况,但是这种表征仍有两处缺陷:

1)缺乏对粒子整体多样性的表征; D_j^p 仅为粒子在各个维度上的位置多样性。

2)计算效率有待改进;从各个维度观测粒子的多样性,就将多样性的衡量从多维问题分解为多个一维计算,没有必要使用各个维度上当前位置与维度中心差的平方,即 L_2 范式。

新的位置多样性定义正是为了解决以上两种定义方式的不足,其定义如下所示:

$$\bar{x} = \frac{1}{m} \sum_{i=1}^m x_{ij} \quad (7)$$

$$D_j^p = \frac{1}{m} \sum_{i=1}^m |x_{ij} - \bar{x}_j| \quad (8)$$

$$D^p = \frac{1}{n} \sum_{j=1}^n D_j^p \quad (9)$$

新的位置多样性定义,即首先求出各个维度上的粒子位置中心,再计算各个粒子位置与中心的 L_1 距离,然后将各个维度上的距离求和并除以粒子个数,用来表征群体在各个维度上的位置多样性,最后将各个维度上的多样性求平均,所得结果便是当前粒子的整体位置多样性。与以上两种定义相比,新的位置多样性定义拥有以下特点:

1)将多样性的计算分解到解的每一维上,从而可以更精确地表征所有粒子在某一时刻的多样性状态。

2)位置多样性的定义拥有更明确的几何意义; \bar{x} 代表当前粒子群在各个维度上的中心, D_j^p 表示粒子在 j 维度上要达到收敛需要平均移动的距离;而粒子群在所有维度上收敛到一点,所有粒子需要移动的总距离为 $m \times n \times D^p = mnD^p$ 。

3) D^p 可以对粒子群整体的位置多样性进行表征, D_j^p 表示粒子群在各个维度上的多样性,这样可以更加清晰地描述算法运行过程中多样性的变化情况。

2.2 速度多样性

位置多样性表征粒子群当前粒子的分布情况,而速度多样性表示当前粒子群体的“活性”,即对粒子运动状态的描述,从中可以观测出粒子群体的发散(expansion)或收敛(convergence)情况。在文献[10,11]给出的速度多样性的定义如下所示:

$$v_{ij}^{ave} = \frac{v_{ij}}{\sqrt{\sum_{j=1}^n v_{ij}^2}} \quad (10)$$

$$\bar{v}_j^{pr} = \frac{1}{m} \sum_{i=1}^m v_{ij}^{pr} \quad (11)$$

$$D_j^v = \frac{1}{m} \sqrt{\sum_{i=1}^m (v_{ij}^{pr} - \bar{v}_j^{pr})^2} \quad (12)$$

与位置多样性的定义相似,速度多样性仍存在两点需要改进:

1) 缺乏对粒子整体速度多样性的表征; D_j^v 仅为粒子在各个维度上的速度多样性。

2) 速度多样性的计算已经分解到解的每一维上,采用 L_1 距离可以比 L_2 距离拥有更明确的几何意义和计算效率。

新的速度多样性定义如下所示:

$$\bar{v} = \frac{1}{m} \sum_{i=1}^m v_{ij} \quad (13)$$

$$D_j^v = \frac{1}{m} \sum_{i=1}^m |v_{ij} - \bar{v}_j| \quad (14)$$

$$D^v = \frac{1}{n} \sum_{j=1}^n D_j^v \quad (15)$$

式中, $\bar{v} = [\bar{v}_1, \dots, \bar{v}_j, \dots, \bar{v}_n]$ 为所有粒子当前速度在各个维度上的均值, D_j^v 表征粒子群在各个维度上的速度多样性,而 D^v 整体上度量粒子群的速度多样性。

2.3 认知多样性

认知多样性的定义与位置多样性的定义类似,仅在多样性计算公式中用历史位置最优值 (p_{best}) 取代了当前位置。认知多样性代表了粒子群历史最优位置的覆盖范围,即粒子当前所找的目标最优值的范围。

与位置多样性的定义相同,已有的认知多样性也包含类似的缺陷。新的基于粒子维度和 L_1 距离的认知多样性定义如下:

$$\bar{p} = \frac{1}{m} \sum_{i=1}^m p_{ij} \quad (16)$$

$$D_j^p = \frac{1}{m} \sum_{i=1}^m |p_{ij} - \bar{p}_j| \quad (17)$$

$$D^p = \frac{1}{n} \sum_{j=1}^n D_j^p \quad (18)$$

式中, $\bar{p} = [\bar{p}_1, \dots, \bar{p}_j, \dots, \bar{p}_n]$ 为所有粒子历史位置最优值在各个维度上的均值, D_j^p 表征粒子群在各个维度上的认知多样性,而 D^p 整体上度量粒子群的认知多样性。

新的群体多样性定义分别从位置、速度、认知 3 方面考察了粒子群在算法运行过程中的变化情况。3 个方面的多样性定义拥有统一的形式和更加清晰的几何意义,可以更精确地表征算法运行过程中粒子的运行情况。

3 实验结果分析

经典基准测试集是用来检测算法性能的常用函数集合^[13],共包含 23 个测试函数。本文从中选取了 12 个函数作为测试集,其中包括 5 个单峰 (unimodal) 函数,分别为: Sphere, Schwefel's P2. 22, Schwefel's P1. 2, Step, Quadric Noise; 7 个多峰 (multimodal) 函数,分别为: Generalized Rosenbrock (当 $n \geq 4$ 时, Generalized Rosenbrock 函数被证明为多峰函数^[14]), Schwefel, Rastrigin, Noncontinuous Rastrigin, Ackley, Griewank 和 Generalized Penalized 函数。

为节省篇幅,本文选取两个函数作为示例,如表 1 所列,其中 Quadric Noise 为单峰函数, Ackley 为多峰函数。算法的参数设置均采用 Bratton 与 Kennedy 提出的标准粒子群算法^[15]。

表 1 基准测试函数示例: n 为函数维度, f_{\min} 为函数最小值,且 Search space $\subseteq \mathbb{R}^n$

Function name	Test function	Dimension	Search space	f_{\min}
Quadric Noise	$f_7(x) = \sum_{i=1}^n ix_i^4 + \text{random}[0, 1]$	25/50	$[-1.28, 1.28]^n$	0
Ackley	$f_{10}(x) = -20e^{-0.2\sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}} - e^{\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)} + 20 + e$	25/50	$[-32, 32]^n$	0

下面将根据实验结果,对多样性的不同定义进行分析,然后展示多样性在不同解空间维数、不同粒子群拓扑结构和不同种群大小上的变化情况。为了兼顾篇幅和全面表示多样性变化的要求,本文仅选取一些有代表性的图例,其中,横轴表示粒子群的迭代次数,纵轴表示观测所得到的粒子群体多样性数值。每项分析均包括 f_7 或 f_{10} 的位置,速度和认知多样性。

3.1 多样性变化分析

图 1 表示不同观测方式下多样性的变化情况,其中图 1(a) 表示函数 f_7 在 3 种定义下的位置多样性,图 1(c) 表示函数在 3 种定义下的认知多样性。从图中可以得出粒子的位置、速度、认知多样性均逐渐递减,并最终趋近于 0。其中速度多样性的变化并非是一个平滑过程,而是一个振荡下降的过程。这也说明了粒子群算法中粒子围绕局部极值中心来回振荡,逐渐缩小与局部极值距离的现象^[16]。

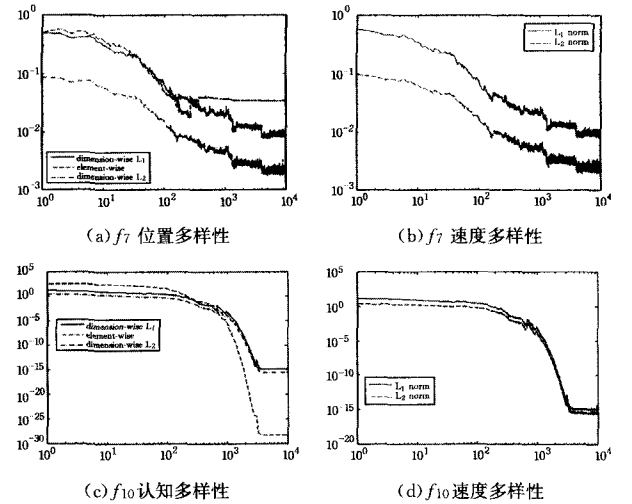


图 1 粒子群算法不同群体多样性定义的比较

从图 1 中可以看出,基于粒子个体的多样性变化比基于维度的多样性变化更为缓慢,且最终数值与 0 有较大距离。这表明基于个体的多样性观测缺乏对算法实际运行过程的表征,因此基于维度的定义比基于个体的定义更能反映算法的实际运行情况。同时,基于 L_1 范式与 L_2 范式的位置多样性变化与认知多样性变化趋势基本一致,而基于 L_1 范式的计算量小于基于 L_2 的计算量,当算法需要迭代多次时,基于 L_1 范式的度量拥有更好的计算效率。此外,基于 L_1 的值比基于 L_2 的值大一个数量级,当粒子群的多样性变化趋于 0 时,使用 L_1 可以更清晰地描述多样性的变化情况。

对使用式(12)中求出的基于维度的粒子速度多样性进行加权平均,可以得到粒子群基于 L_2 范式的整体速度多样性。将此多样性度量与基于 L_1 范式的多样性度量进行比较。图 1(b) 表示函数 f_7 的速度多样性,图 1(d) 表示函数 f_{10} 的

速度多样性。从图中可以看出基于 L_1 和基于 L_2 的测量拥有相同的变化趋势,而基于 L_1 范式的度量拥有计算量小、变化范围大、表征更清晰的优势。

3.2 多样性在不同解空间维数的观测

图 2 表示多样性在不同解空间维数 ($D=25$ 或 $D=50$) 时的变化情况。其中图 2(a) 为 f_7 位置多样性,图 2(b) 为 f_7 速度多样性,图 2(c) 为 f_{10} 速度多样性。对于 f_7 函数,当 $D=25$ 时,适应度计算 250000 次, $\min(f_7) = 6.170972E-05$; 当 $D=50$ 时,适应度计算 500000 次, $\min(f_7) = 0.001694$ 。从图中可以看出,在不同的解空间维数上, f_7 函数的速度和位置多样性的变化趋势基本一致,且速度多样性和位置多样性的值与维数的大小成正比。维数越大,在相同的迭代次数时,群体多样性的数值越大,算法收敛于极值点的速度越慢。

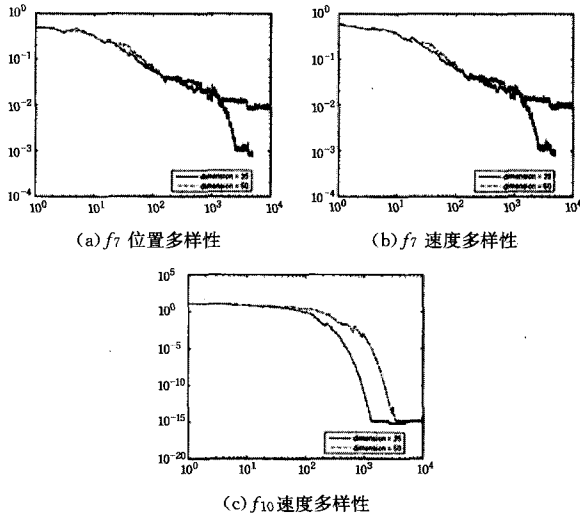


图 2 群体多样性在粒子群算法不同解空间维数时的观测

对于 f_{10} 函数,当 $D=25$ 时,适应度计算 250000 次, $\min(f_{10}) = 7.549516E-15$; 当 $D=50$ 时,适应度计算 500000 次, $\min(f_{10}) = 2.886579E-14$ 。与函数的多样性变化相似,在不同解空间维数上, f_{10} 函数都表现出相同的认知和速度多样性变化趋势,但在低维数上, f_{10} 函数的群体多样性值都远小于维数较高的情况。

通过对多样性的观测,解释了算法对函数求最优值的过程中,在低维的解空间上比高维可以获得更“好”的优化值。粒子群算法拥有较小的位置多样性,表明算法可以在较小的空间内进行搜索,而较小的速度多样性表明算法拥有更大的“开发”能力。

通过上面的讨论可以看出,虽然解空间维数不同,但是新的基于 L_1 范式的群体多样性观测仍可以正确地表征算法的运行情况。

3.3 多样性在不同粒子群拓扑结构上的观测

图 3 显示了群体多样性在不同粒子群拓扑空间结构即星形(global star)或环状(local ring)上的变化情况。图 3(a) 为 f_7 认知多样性,图 3(b) 为 f_7 速度多样性;图 3(c) 为 f_{10} 位置多样性,图 3(d) 为 f_{10} 速度多样性。解空间维数 $D=50$,适应度计算 500000 次,对于 f_7 函数,此次运算 global 结构最优值 $\min(f_7) = 0.001694$; local ring 结构最优值 $\min(f_7) = 0.027210$,采用 global 结构取得最优值略小于 local ring 结构。对于 f_{10} 函数,此次运算 global 结构最优值 $\min(f_{10}) = 2.886579E-14$; local ring 结构最优值 $\min(f_{10}) = 1.506794E-12$ 。

Local ring 结构获得的最优值稍小于 global 结构。

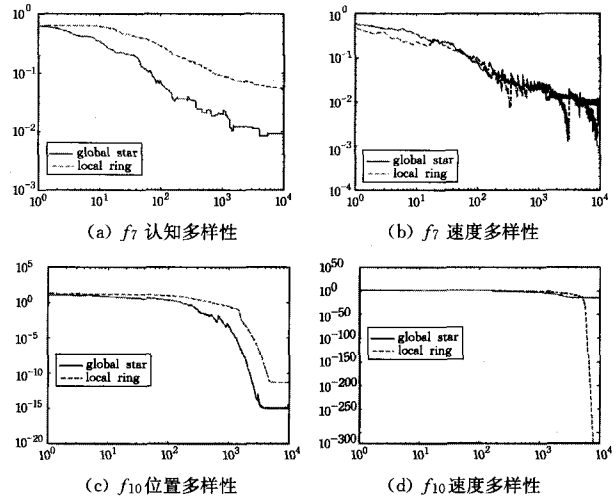


图 3 群体多样性在粒子群采取不同拓扑结构时的观测

函数求极值的过程需要在多样性的观测中得到正确的反映, f_7 函数采用 global 结构的极值略小于采用 local ring 结构时的极值,表现在多样性上,即为速度多样性趋势大概相同,且 global 结构速度多样性值略小于 local ring 结构,而认知多样性的观测值明显小于 local ring 结构。对于函数 f_{10} ,采用 local ring 结构时获得的极值稍小于 global 结构。这也在多样性的衡量中得到明显的表征。Local ring 结构的位置多样性数值稍大于 global 结构,且速度多样性在计算末期陡然下降,导致粒子群丧失继续探索最优值的能力,陷入了局部最优。

通过上面的讨论可以看出,新的基于 L_1 范式的多样性观测方式可以正确地表征同一问题在不同粒子群结构上的变化情况。

3.4 多样性在不同粒子个数上的观测

图 4 显示了多样性在不同粒子数目 ($p=50$ 或 $p=100$) 上的变化情况,图 4(a) 为 f_7 速度多样性,图 4(b) 为 f_{10} 位置多样性,图 4(c) 为 f_{10} 速度多样性。当解空间维数 $D=50$,适应度计算 500000 次, $p=50$ 时, $\min(f_7) = 0.001694$, $\min(f_{10}) = 2.886579E-14$; $p=100$ 时, $\min(f_7) = 0.002555$, $\min(f_{10}) = 1.465494E-14$ 。

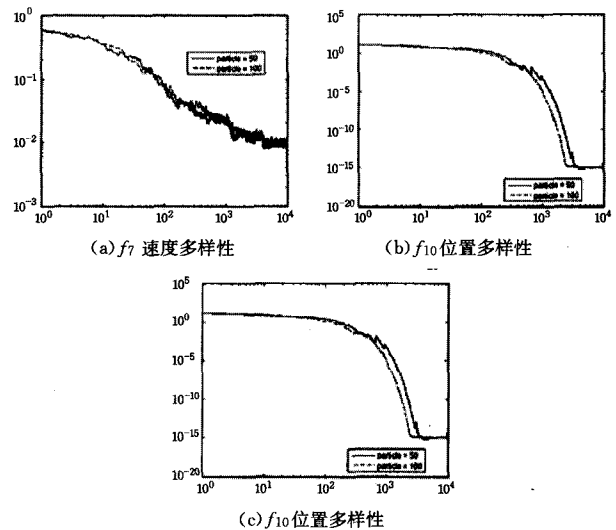


图 4 群体多样性在粒子群算法不同粒子个数时的观测

(下转第 239 页)

of the 14th Biennial Conference of the Canadian Society for Computational Studies of Intelligence, 2001:204-214

- [15] Zhang M-L, Zhou Z-H. Adapting RBF Neural Networks to Multi-Instance Learning[J]. Neural Processing Letters, 2006, 23(1):1-26
- [16] Wang Jun, Zucker J-D. Solving the multiple-instance problem: a lazy learning approach[C]//Proceeding of the 17th Intl. Conf. Mach. Learn. 2000;1119-1125
- [17] Stuart A, Thomas H, Ioannis T. Multiple instance learning with generalized support vector machines [C]// Proceeding of the 18th National Conference on Artificial Intelligence, 2002;943-944
- [18] Zhou Zhi-hua, Xu Jun-ming. On the relation between multi-instance On the relation between multi-instance learning and semi-supervised learning [C]// Proceeding of the 24th Intl. Conf. Mach. Learn. 2007;1167-1174
- [19] Kwok J T, Cheung P-M. Marginalized multi-instance kernels[C]// Proceeding of the 20th International Joint Conference on Artificial Intelligence. Hyderabad, India, 2007;901-906
- [20] Zhou Z-H, Sun Y-Y, Li Y-F. Multi-instance learning by treating instances as non-I. I. D. samples[C]//Proceeding of the the 26th

Intl. Conf. Mach. Learn. 2009;1249-1256

- [21] Chen Yi-xin, Wang J Z. Image categorization by learning and reasoning with regions [J]. Journal of Machine Learning Research, 2004, 5(8):913-939
- [22] Kim M, De la Torre F. Gaussian Processes Multiple Instance Learning[C]//Proceeding of the 27th Intl. Conf. Mach. Learn. 2010;535-542
- [23] Deselaers T, Ferrari V. A Conditional Random Field for Multiple-Instance Learning[C]// Proceeding of the 27th Intl. Conf. Mach. Learn. 2010;287-296
- [24] Wei Ping, Ye Xu, Non-I. I. D. Multi-Instance Dimensionality Reduction by Learning a Maximum Bag Margin Subspace[C]// Proceeding of 24th AAAI Conference on Artificial Intelligence. 2010;551-556
- [25] Sun Yu-yin, Ng M K, Zhou Zhi-hua. Multi-Instance Dimensionality Reduction[C]// Proceeding of 24th AAAI Conference on Artificial Intelligence. 2010;587-592
- [26] Rubner Y, Tomas C, Guibas L J. The earthmover's distance as a metric for image retrieval [J]. International Journal of Computer Vision, 2000, 40(2):99-121

(上接第 193 页)

粒子群算法在不同粒子数目时,得到的极值不同,表明算法的求解过程存在着差异,而多样性的观测要能够正确地表征这种信息。

采用不同的粒子个数, f_7 函数的最优值处在同样的数量级, 50 个粒子的情况稍好于 100 个粒子, 反映到多样性的变化上, 如图 4(a) 所示。算法在不同粒子个数上, 认知和速度多样性变化趋势基本相同, 50 个粒子时多样性的最终数值略小于 100 个粒子的情况。而对于函数, 100 个粒子时的最优值稍小于 50 个粒子的情况, 对应到多样性的变化上, 如图 4(b)、(c) 所示, 100 个粒子时位置和速度的多样性收敛也稍早于 50 个粒子。

通过以上讨论可以得出, 新的基于 L_1 范式的群体多样性观测可以正确地反映粒子群优化在不同粒子数目上的运行信息。

结束语 在本文中, 分析了不同的群体多样性定义方式的优缺点, 提出了一种新的观测方式; 并通过实验观测粒子群算法在不同解空间维数、不同粒子群拓扑结构和不同种群大小上的多样性变化情况, 验证了新的群体多样性观测表征粒子群算法运行状态的准确性和新的观测方式的通用性。新的观测方式减少了已有方法的计算量, 并提供了变化范围更广泛的观测值, 从而可以更清晰地观测粒子群算法执行过程中粒子的运动。

通过多样性的观测, 分析粒子群体在算法执行过程中位置、速度和认知变化信息, 进而找出有效地间接或者直接的控制多样性的方法, 就可以动态地改变粒子群的“探索”或“开发”的阶段和能力, 从而取得更好的优化效果。

参考文献

- [1] Eberhart R, Kennedy J. A new optimizer using particle swarm theory [C] //Proc of the Sixth International Symposium on Micro Machine and Human Science, 1995;39-43
- [2] Kennedy J, Eberhart R. Particle swarm optimization [C]//Proc

of IEEE International Conference on Neural Networks(ICNN). 1995;1942-1948

- [3] Eberhart R, Kennedy J, Shi Yu-hui. Swarm Intelligence [M]. Morgan Kaufmann Publisher, 2001
- [4] Eberhart R, Shi Yu -Hui. Computational Intelligence: Concepts to Implementations[M]. Morgan Kaufmann Publisher, 2007
- [5] Engelbrecht A. Fundamentals of Computational Swarm Intelligence [M]. John Wiley & Sons Ltd, 2005
- [6] 谭营. 计算群体智能基础 [M]. 北京:清华大学出版社, 2009
- [7] 张军, 詹志辉, 等. 计算智能 [M]. 北京:清华大学出版社, 2009
- [8] Zhan Zhi-hui, Zhang Jun, Li Yun, et al. Adaptive particle swarm optimization [J]. IEEE Transactions on Systems, Man, and Cybernetics-Part B: Cybernetics, 2009, 139(6):1362-1381
- [9] Golub G, Van Loan C. Matrix Computations(third edition)[M]. The Johns Hopkins University Press, 1996
- [10] Shi Yu-hui, Eberhart R. Population diversity of particle swarms [C]//Proc of the 2008 Congress on Evolutionary Computation. 2008;1063-1067
- [11] Shi Yu-hui, Eberhart R. Monitoring of particle swarm optimization [J]. Frontiers of Computer Science, 2009, 3(1):31-37
- [12] Zhan Zhi-hui, Zhang Jun, Shi Yu-hui. Experimental study on PSO diversity [C]//Third International Workshop on Advanced Computational Intelligence. Jiangsu, china, August 2010;310-317
- [13] Yao Xin, Liu Yong, Lin Guang-ming. Evolutionary programming made faster [J]. IEEE Transactions on Evolutionary Computation, 1999, 3(2):82-102
- [14] Shang Yun-wei, Qiu Yu-huang. A note on the extended rosenbrock function [J]. Evolutionary Computation, 2006, 14(1):119-126
- [15] Bratton D, Kennedy J. Defining a standard for particle swarm optimization [C]//Proc of the 2007 IEEE Swarm Intelligence Symposium(SIS 2007). 2007;120-127
- [16] Spears W, Green D, Spears D. Biases in particle swarm optimization [J]. International Journal of Swarm Intelligence Research, 2010, 1(2):34-57