

文章编号: 1001-0920(2007)12-1411-06

## 基于双变异算子的免疫规划

薛文涛, 吴晓蓓, 徐志良

(南京理工大学 自动化学院, 南京 210094)

**摘要:** 针对进化规划的早熟收敛问题, 借鉴免疫系统的应答机制, 并结合进化规划与免疫机理, 提出一种基于双变异算子的免疫规划算法 (DMIP). 该算法的核心在于采用全局柯西变异算子和局部高斯变异算子, 通过保持种群的多样性和执行记忆保护以及弱小保护策略, 保证了算法搜索的快速性和有效性. 理论分析和仿真结果均表明, 该方法能够有效地提高算法的全局及局部搜索能力, 克服早熟现象.

**关键词:** 进化规划; 免疫规划; 全局柯西变异; 局部高斯变异; 多样性

**中图分类号:** TP18

**文献标识码:** A

## Immune programming based on double mutation operators

XUE Wen-tao, WU Xiao-bei, XU Zhi-liang

(Institute of Automation, Nanjing University of Science and Technology, Nanjing 210094, China. Correspondent: XUE Wen-tao, E-mail: xuewt2002@yahoo.com)

**Abstract:** For the problem of premature convergence of conventional evolutionary programming, an immune programming based on double mutation operators (DMIP) is proposed. The algorithm combines evolutionary programming with immune mechanism in view of the mechanism of immune response. The key to the algorithm lies in using global Cauchy mutation operator and local Gauss mutation operator. In order to make the searching rapid and effective, DMIP maintains the diversity of population and performs memory protection and immature protection. The theoretical analysis and simulation results show that the algorithm can improve the ability of searching global optimization and overcome premature convergence effectively.

**Key words:** Evolutionary programming; Immune programming; Global Cauchy mutation; Local Gauss mutation; Diversity

### 1 引言

自 Fogel 提出进化规划 (EP) 以来, 进化规划作为进化算法的一个分支, 已经成功地解决了函数优化<sup>[1]</sup>、神经网络优化<sup>[2]</sup>和组合优化<sup>[3]</sup>等问题. 与确定性算法相比, 进化规划有更多的机会求得全局最优解, 但进化规划维持群体多样性能力较弱, 陷入局部最优后难以跳出, 易发生早熟收敛<sup>[4]</sup>.

为了改善进化规划的性能, 文献[5]提出一种快速进化规划方法 (IFEP), 通过剔除进化中的非法个体, 提高了算法的全局收敛速度. 但由于进化后期非法个体变少, 对每个新个体执行合法判断浪费的时间增多, 而且算法并未改善其局部搜索的能力. 文献[6]提出一种改进的进化规划算法, 采用步长修正策略来提高算法的计算精度和收敛速度. 但该算法不能保证变异产生的新个体在进化早期就进入全局最

优解的邻域, 当算法陷入局部最优时, 过小的压缩因子使得步长不足以跳出局部最优区域.

免疫系统具有较强的自适应性、多样性、学习、识别和记忆等特点<sup>[7]</sup>, 它为智能优化技术提供了新的契机. 王磊等<sup>[8]</sup>设计了一种接种疫苗的免疫规划 (IP) 方法, 并应用于函数和 TSP 问题的优化. 付利华等<sup>[9]</sup>利用免疫规划 (IEP) 优化模糊神经网络参数, 用以控制一级倒立摆. 将免疫机理与进化规划相结合, 为解决优化问题提供了一条新的途径. 本文借鉴免疫机理, 提出一种基于双变异算子的免疫规划算法 (DMIP), 利用抗体的浓度来维持抗体群的多样性, 对全局收敛有益的抗体采用保护措施, 并通过双变异算子提高算法的全局和局部搜索能力. 理论分析和函数优化仿真实验均证明了此种算法具有良好的性能.

收稿日期: 2006-09-11; 修回日期: 2007-01-29.

作者简介: 薛文涛 (1974—), 男, 郑州人, 博士生, 从事免疫算法、进化算法等研究; 吴晓蓓 (1958—), 女, 成都人, 教授, 博士生导师, 从事智能控制、网络控制等研究.

## 2 基于双变异算子免疫规划的主要思想

在算法结构上,变异机制和选择方式是进化规划的两大要素.变异算子是进化规划产生新个体的唯一手段,而单一变异算子则较难使得算法同时具有很好的全局和局部搜索能力,所以DMIP采用双变异算子来分别加强算法的全局和局部搜索能力,以改善进化规划的搜索性能.为了保持种群的多样性,DMIP采取基于浓度的 $q$ 竞争选择策略,克隆种群中得分高的抗体,并抑制种群中相似的抗体,从而有效地阻止早熟现象的发生.DMIP执行记忆保护和弱小保护策略,利用这些有利于全局收敛的个体,将使算法尽快收敛到全局最优解.

DMIP用抗原对应目标函数,抗体对应目标函数的解个体,抗体群形成目标函数的解空间,将算法归纳为变异、选择、记忆保护、弱小保护4大部分.

### 2.1 双变异算子

与高斯和平均变异算子相比,柯西变异算子能以更大的概率产生大的变异值<sup>[10]</sup>,从而在全局搜索上会更有优势,可以保证算法在整个解空间内搜索最优解,并提高算法摆脱局部极值的能力.在一些确定性优化算法中,单纯性法、模式搜索等优化算子具有很好的局部搜索能力,但随着优化问题的约束条件和变量数目增加,这些算法的迭代次数将迅速增加,甚至会以指数上升,导致收敛速度缓慢.而在高维的优化问题上,文献[11]证明了平均变异算子的局部搜索能力不如高斯变异算子.因此,为了兼顾全局搜索和局部搜索,本文设计了两种变异算子,其中全局柯西变异算子在解空间内大范围地搜索全局最优解,提高算法的局部逃逸能力,保证算法具有良好的全局搜索能力;局部高斯变异算子用于提高算法的局部搜索能力,保证算法能以较高的精度找到全局最优解.

#### 2.1.1 全局柯西变异算子

在全局柯西变异算子的作用下,种群 $X_C$ 中的父代 $(x_i, \sigma_i)$ 生成子代 $(x_i', \sigma_i')$ ,即

$$x_i'(j) = x_i(j) + \sigma_i'(j) C_j(0, 1), \quad (1)$$

$$\sigma_i'(j) = \sigma_i(j) \exp\left(\lambda \frac{\text{aff}_{x_i} - \text{aff}_{\text{ave}}}{\text{aff}_{\text{max}} - \text{aff}_{\text{min}}}\right). \quad (2)$$

其中: $i = 1, \dots, m$ ,  $m$ 为 $X_C$ 种群的数量; $j = 1, \dots, n$ ,  $n$ 为目标解的维数; $C_j(0, 1)$ 为对分量 $j$ 产生一个比例参数为1的柯西随机变量;求极大值问题时取 $\lambda = -1$ ,求极小值问题时取 $\lambda = 1$ ;  $\sigma_i$ 的初始值 $\sigma_0 = \xi_i \times L_j$ ,  $L_j$ 为各目标解区间的长度; $\text{aff}_{x_i}$ 为抗体 $x_i$ 的亲和度,  $\text{aff}_{\text{max}}$ 为当代种群的最大亲和度,  $\text{aff}_{\text{min}}$ 为当代种群的最小亲和度,  $\text{aff}_{\text{ave}}$ 为当代种群的平均亲和度,即

$$\text{aff}_{\text{ave}} = \frac{1}{m} \sum_{i=1}^m \text{aff}_{x_i}.$$

由式(2)可知,当求极小值问题时,若 $\text{aff}_{x_i} < \text{aff}_{\text{ave}}$ ,则说明抗体相对较好,需减少步长,以便仔细搜索该区域;若 $\text{aff}_{x_i} > \text{aff}_{\text{ave}}$ ,则说明抗体相对较差,需增大步长,以便尽快搜索到较好的区域.当求极大值问题时,正好相反.

虽然柯西变异较高斯变异更容易逃离函数的局部极值,但当搜索接近全局最优解时,柯西变异过大的步长很容易跳出好的区域而产生较差的子代.特别是当函数为多峰分布且最优解和局部极值相差不大时,极易使算法陷入几个峰之间的搜索中,而高斯变异在小范围内却具有很好的搜索能力<sup>[10]</sup>.因此,本文增加了局部高斯变异算子,通过步长不断地自适应调整,使算法逐渐逼近全局最优解.

#### 2.1.2 局部高斯变异算子

为了提高算法的局部收敛能力,选用局部高斯变异算子,通过小步长来加强算法在局部搜索极值的能力.种群 $X_N$ 中的父代 $(x_i, \sigma_i)$ 和子代 $(x_i', \sigma_i')$ 的关系如下:

$$x_i'(j) = x_i(j) + \sigma_i'(j) N_j(0, 1), \quad (3)$$

$$\sigma_i'(j) = \sigma_i(j) \exp\left(\frac{-\mu k + \sqrt{\mu k}}{2}\right). \quad (4)$$

其中: $i = 1, \dots, m$ ,  $m$ 为 $X_N$ 种群的数量; $j = 1, \dots, n$ ,  $n$ 为目标解的维数; $N_j(0, 1)$ 为分量 $j$ 的标准正态分布的随机变量; $\sigma_i$ 的初始值 $\sigma_0 = \xi_i \times L_j$ ;  $\mu$ 为比例系数,  $0 < \mu \leq 0.1$ 控制步长在小的范围内变化,  $\mu$ 取值与目标函数期望的精度有关; $k$ 为进化代数.

为了防止变异后的子代超出目标函数的解空间 $[a_j, b_j]$ ,  $j = 1, \dots, n$ ,  $n$ 为目标解的维数,子代的取值原则是<sup>[12]</sup>:如果 $x_i'(j) > b_j$ ,则 $x_i'(j)$ 取 $2b_j - x_i'(j)$ 的值;如果 $x_i'(j) < a_j$ ,则 $x_i'(j)$ 取 $2a_j - x_i'(j)$ 的值.

### 2.2 基于浓度的 $q$ 竞争策略

EP采取 $q$ 竞争选择策略,即种群中父代与子代一起参与 $q$ 排序竞争.这种选择策略使得亲和度好的个体较易获胜,并保留了父代较优的个体.然而,这种选择方法也会造成多样性的失衡,一些邻近但亲和度较好的个体将在种群中占统治地位,而一些可能是在最优区域但亲和度较差的个体将被过早地淘汰,算法易发生早熟现象.为了保持多样性,种群中必须排斥相似的个体,使个体尽量散布整个解空间.为此,本文将免疫系统的浓度调节机制融入到EP的 $q$ 竞争策略中.

**定义1** 某代种群不同的两个抗体 $x_i$ 与 $x_k$ 之间的相似度为

$$A_{x_i,x_k} = 1 - \frac{\sum_{j=1}^n |x_i(j) - x_k(j)|}{\sum_{j=1}^n (b_j - a_j)} \tag{5}$$

其中: $i,k=1,\dots,N$ ,且 $i\neq k$ , $N$ 为种群数量; $j=1,\dots,n$ , $n$ 为目标解的维数值.

定义 2 对于种群数量为  $N$ ,抗体  $x_i$  的浓度定义为

$$c_i = \frac{\text{Count}(A_{x_i,x_k} \geq \gamma)}{N} \tag{6}$$

其中: $\text{Count}(\cdot)$  为计算数量的函数; $\gamma$  为相似度常数,一般取  $0.8 \leq \gamma \leq 1$ .

对抗体群中任一抗体  $x_i$ ,随机从余下的整个父、子代种群  $2N-1$  个抗体中选择  $q$  个抗体,依次将其亲和度与  $q$  个抗体的亲和度相比较.若  $x_i$  的亲和度好,则其得分加 1,比较完后,累加分数得到抗体  $x_i$  的得分.为了抑制相似抗体,提高种群的多样性,在  $q$  竞争得分的基础上,增加基于浓度的调节因子,则抗体  $x_i$  调整后的得分为

$$p_i' \cdot \text{scores} = (1 + \alpha \cdot \exp(-c_i/\beta)) p_i \cdot \text{scores} \tag{7}$$

其中: $p_i \cdot \text{scores}$  为抗体  $x_i$  在  $q$  竞争中的得分; $\alpha$  和  $\beta$  为调节因子, $0 < \alpha \leq 1, 0 < \beta \leq 1$ .

从式(7) 可看出,抗体的得分越大, $p_i' \cdot \text{scores}$  越大;抗体浓度越大, $p_i' \cdot \text{scores}$  越小.这样,既保留了亲和度好的抗体,又减少了相似抗体的选择.

2.3 记忆保护策略

采用基于浓度的  $q$  竞争策略,竞争中得分最高的抗体未必是亲和度最优的抗体,而是亲和度较好且浓度较低的抗体.通过建立优良记忆库,将历代亲和度最优的抗体保留下来,实现种群的精英保留策略,而且对亲和度较优的抗体还要引入竞争机制,以便能搜索到全局最优,实现精英选择机制.

从初始种群中取小部分亲和度最优的抗体组成优良记忆库.如果所求目标函数要求极小值,则对每代进化的抗体群取一定比例的低亲和度抗体加入到优良记忆库中,替代库中亲和度较高的抗体;反之亦然.设立优良记忆库是为了保证算法终止时得到的结果是历代最优的抗体;优良记忆库中的抗体参与竞争是为了保证较佳的抗体无条件地被克隆到下一代,以加快算法收敛到全局最优的速度.

2.4 弱小保护策略

对于一个复杂的优化问题,全局最优解所在的区域和大小是未知的.因此,在扩大种群多样性的同时,还要关注一些可能有助于搜索到全局最优解的个体.如果最优解附近区域的分布比较陡峭,则区域

内抗体亲和度的差别就会较大,全局最优解的一些邻近解将是亲和度较差的抗体.因此,将那些子代亲和度有较大改进的低亲和度抗体保护起来,能促使算法有更多的机会仔细搜索该区域,有利于局部区域的搜索<sup>[13]</sup>.

将种群中亲和度较差的抗体进行子代比较,把亲和度改进最大的父代抗体保留下来,使其在下代进化中承担起局部搜索的任务,从而提高算法搜索到全局最优的概率.

3 DMIP 算法

3.1 算法步骤

Step1: 抗体编码. 本文抗体  $x$  采用实数制编码,编码长度为  $n$ , $S$  为解空间.

Step2: 产生初始抗体群  $X(0)$ . 随机产生  $N$  个初始抗体组成  $X(0)$ ,  $N$  为偶数.

Step3: 将  $N$  个抗体群  $X(k)$  均分成 2 个子群体  $X_C$  和  $X_N$ .

Step4: 计算种群  $X_C$  和  $X_N$  每一个抗体与抗原的亲和度.从整个种群中提取最好的  $10\% N$  (有余数则四舍五入取整) 个抗体组成优良记忆库  $X_M$  (在以后的进化中,只进行优良记忆库更新).

Step5:  $X_C$  种群采取全局柯西变异生成子种群  $X_C'$ ;  $X_N$  种群采取局部高斯变异生成子种群  $X_N'$ .

Step6: 计算子种群  $X_C'$  和  $X_N'$  中抗体的亲和度,并进行优良记忆库更新.从子代种群中取最好亲和度的抗体替换优良记忆库中  $5\% N$  较差的亲和度抗体,实现优良记忆库更新.

Step7: 执行弱小保护策略.根据种群变异前后亲和度大小的比较,找出子代比父代改进最大的  $10\% N$  个父代抗体保留下来,得到群体  $X_I$ .

Step8: 群体更新.将种群  $X_C, X_N, X_C'$  和  $X_N'$  组成群体  $X_S$ ,对  $X_S$  采取基于浓度的  $q$  竞争选择,其中父代种群  $X_C, X_N$  与  $X_M, X_I$  相同的抗体,其得分赋值为一大于  $2q$  的常数  $C$ .选取  $X_S$  中得分排在前的  $N$  个抗体组成下一代的抗体群  $X(k+1)$ .

Step9: 收敛性判断.如果满足收敛条件,或达到进化的代数,则结束进化进程,从优良记忆库中取最好的抗体得出全局最优解,否则,返回 Step3.

3.2 算法收敛性能的改进

对于 CEP 算法,由于种群多样性随进化代数迅速减少,造成搜索范围变小.若变异算子不能引导算法搜索到最优区域,则极易发生早熟现象.本文以一维 Ackley 函数极小值优化为例,分析 DMIP 能改进 EP 收敛性能的理由,如图 1 所示.

1) 在 CEP 中,变异算子选用  $N(0,1)$  高斯分布作为步长的系数,而在全局柯西变异算子中则选用




图1 Ackley一维函数

$Q(0,1)$  作为步长系数. 在变异绝对值范围为  $[0, \infty)$  区间上,柯西算子能以较大的概率产生大于 2 的变异值,而高斯算子产生的变异值则更多地落在  $[0.6, 2]$  区间上<sup>[10]</sup>. 在进化前期,DMIP 可以依靠大步长扩展搜索领域. 当有个体在  $[x_1, x_7]$  区域外时,在大步长的变异下,算法搜索到最优区域  $[x_2, x_5]$  的概率显然比小步长的概率大.

2) CEP 步长

$$\sigma_i' = \sigma_i \exp(\tau' N(0,1) + \tau N_j(0,1)),$$

其中  $\tau$  和  $\tau'$  分别为  $(\sqrt{2} \sqrt{n})^{-1}$  和  $(\sqrt{2} n)^{-1}$ . 当函数的维数确定后,  $\tau$  和  $\tau'$  的值也确定. 所以子代步长随  $N_j(0,1)$  随机变化,其随机性无法保证算法快速准确地向最优解靠近. 而在 DMIP 中,则借亲和度的变化来指导步长的改变. 当群体在  $[x_5, x_7]$  区域时,假设种群平均亲和度的值为  $f(x_6)$ ,如果个体在  $[x_6, x_7]$  之间,其亲和度高于  $f(x_6)$ ,则加大步长有利于向减小亲和度的方向趋进;如果个体在  $[x_5, x_6]$  之间,其亲和度低于  $f(x_6)$ ,则减小步长有利于仔细搜索该区域,判断是否有更好的解在附近. 通过这样搜索可以加大全局搜索的效率.


3) 为了加强局部搜索能力,DMIP 引入了局部高斯变异算子. 随着进化代数  $k$  不断增大,搜索逐渐靠近最优区域,亲和度差距变化减少,使用小步长变异使得局部搜索时搜索点比较集中,容易搜索到更好的解. 若某代个体  $x_3$  位于最优解  $x^*$  附近,而  $|x_3 - x^*| < 0.1$ ,则必须依靠小步长才能到达最优点,而局部高斯变异可以提供足够小的步长,以使算法能搜索到最优点.

4) 在  $x_4$  附近的个体,亲和度不如  $x_2$  和  $x_5$  附近的个体,但  $x_4$  更靠近最优解  $x^*$ ,即  $x_4$  的子代可能优于  $x_2$  和  $x_5$  的子代. 所以,DMIP 采用弱小保护策略有利于改善算法的全局收敛性能,提高搜索到全局最优解的概率.


4 优化函数的仿真实验

本文选用 Benchmark 问题中的 4 个测试函数<sup>[14]</sup> 作为算法的优化实例,函数表达式如下:


$$\begin{aligned} f_1(x) &= \sum_{i=1}^n (x_i^2 - 10 \cos(2\pi x_i) + 10), \\ &- 5.12 \leq x_i \leq 5.12; \\ f_2(x) &= \\ &- 20 \exp\left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \\ &\exp\left(\frac{1}{n} \sum_{i=1}^n \cos 2\pi x_i\right) + 20 + e, \end{aligned}$$




(a)  $f_1$  函数



(b)  $f_2$  函数



(c)  $f_3$  函数



(d)  $f_4$  函数

图2 算法的优化性能比较

表 1 DMIP 和 CEP,FEP 优化结果比较

| 函数                    | 函数最优值      | 成功收敛标准           | 算法   | 所得最好解                 | 成功次数 | 失败次数 | 平均收敛到最优解代数 |
|-----------------------|------------|------------------|------|-----------------------|------|------|------------|
| $f_1$<br>( $n = 30$ ) | 0          | $\leq 0.02$      | CEP  | 0.065                 | 0    | 20   | —          |
|                       |            |                  | FEP  | 0.004                 | 3    | 17   | 2 045      |
|                       |            |                  | DMIP | $1.35 \times 10^{-4}$ | 16   | 4    | 868        |
| $f_2$<br>( $n = 30$ ) | 0          | $\leq 0.02$      | CEP  | 0.006                 | 2    | 18   | 2 115      |
|                       |            |                  | FEP  | 0.002                 | 7    | 13   | 1 464      |
|                       |            |                  | DMIP | $7.42 \times 10^{-5}$ | 18   | 2    | 414        |
| $f_3$<br>( $n = 30$ ) | - 12 569.5 | $\leq - 12\ 500$ | CEP  | - 12 404.3            | 0    | 20   | —          |
|                       |            |                  | FEP  | - 12 521.4            | 4    | 16   | 1 167      |
|                       |            |                  | DMIP | - 12569.5             | 17   | 3    | 384        |
| $f_4$<br>( $n = 2$ )  | - 1.031 63 | $\leq - 1.02$    | CEP  | - 1.031 63            | 18   | 2    | 58         |
|                       |            |                  | FEP  | - 1.031 63            | 18   | 2    | 46         |
|                       |            |                  | DMIP | - 1.031 63            | 20   | 0    | 21         |

$$-32 \leq x_i \leq 32;$$
$$f_3(x) = \sum_{i=1}^n -x_i \sin(\sqrt{|x_i|}),$$
$$-500 \leq x_i \leq 500.$$
$$f_4(x) =$$
$$4x_1 - 2.1x_1^4 + \frac{1}{3}x_1^6 + x_1x_2 -$$
$$4x_2^2 + 4x_2^4, -5 \leq x_1, x_2 \leq 5.$$

本文用 DMIP 和 CEP,FEP<sup>[14]</sup> 分别求解 4 个函数的最小值,并通过 20 次仿真实验比较三者的优化能力.

3 种算法的种群规模均设为  $N = 100,q = 40$ ,最大进化代数 为 1 500 代,其中函数  $f_4$  为 100 代.对前 3 个函数的优化中,DMIP 的参数为  $\mu = 0.02,\gamma = 0.9,\alpha = 0.5,\beta = 0.65,\xi_1 = 0.01,\xi_2 = 0.015$ ;对  $f_4$  的优化中,DMIP 的参数为  $\mu = 0.1,\gamma = 0.9,\alpha = 0.4,\beta = 0.5,\xi_1 = 0.02,\xi_2 = 0.03$ .两函数的优化结果收敛曲线如图 2 所示,优化结果如表 1 所示.

从收敛的结果可以看出,DMIP 的寻优能力和收敛速度与 CEP,FEP 相比有了较大的改进.根据 IFEP 算法<sup>[5]</sup> 和 BEP 算法<sup>[12]</sup> 给出的收敛结果,DMIP 的收敛精度和速度要优于前二者.

1) CEP和 FEP在进化过程中,种群多样性不断减少,使得进化趋向收敛于一些邻近的优秀个体,对于处理多峰、多局部极值的复杂函数,算法容易发生早熟或进化缓慢,如图 2(c) 所示.而 DMIP 采用浓度机制保证种群的多样性,使得种群中的个体散布整个空间,有利于搜索到全局最优的区域.

2) FEP比 CEP有了较强的逃逸能力,所以在一些函数的收敛后期,FEP 能跳出局部极值,获得较好的收敛结果.而 DMIP 采用双变异算子,保留了柯西算子产生大步长的优点,又增加了高斯变异下小步长局部搜索的优势,所以初期有很大的收敛速度,到后期向亲和度改善的方向进化,逐渐获得较好的精度,如图 2(a) 所示.

3) 在低维、区间小的函数优化上,FEP 不比 CEP 有更多的优势,但早期的收敛速度会快一些.而 DMIP 则保留了对全局收敛有益的抗体,大大提高了算法的准确性和快速性.在高维优化问题上,由于 DMIP 改善了算法的多样性和搜索能力,收敛的成功率和平均收敛代数明显优于 CEP 和 FEP.

5 结 语

本文结合免疫机理的思想,对标准进化规划进行了改进,提出了一种基于双变异算子的免疫规划(DMIP).仿真实验表明,该算法的寻优能力和收敛速度与 CEP 和 FEP 相比有了较大的改进.DMIP 通过采用全局柯西变异算子和局部高斯变异算子,在保证良好的全局搜索能力上,增强了算法局部搜索能力,使得算法能够快速向全局最优解收敛;通过抗体浓度的抑制和促进,保持了种群的多样性,使得算法不易过早地陷入局部极值.同时,记忆保护、弱小保护策略中保留了有益的抗体,利用它们寻优的潜力,算法可以更高效地找到全局最优解.本文算法适合于数值函数的优化,还可应用于一些实际优化问题,但本文没有分析所选参数对算法性能的影响,以及如何在保持有利于全局收敛的多样性条件下,利用变异算子不断缩小搜索范围,这些都有待进一步研究.

参考文献(References)

[1] Xin Yao. Global optimisation by evolutionary algorithms [C].2nd Aizu Int Symposium on Parallel Algorithms / Architecture Synthesis. Aizur Wakamatsu, 1997: 282-291.

[2] Xin Yao, Yong Liu. A new evolutionary system for evolving artificial neural networks[J]. IEEE Trans on Neural Networks, 1997, 8(3): 694-713.

[3] Ling Wang, Da-zhong Zheng. A modified evolutionary programming for flow shop scheduling[J]. The Int J of Advanced Manufacturing Technology, 2003, 22 (7/8): 522-527.

- [4] 林丹, 李敏强, 寇纪淞. 进化规划中防治早熟收敛的方法[J]. 系统工程学报, 2001, 16(3): 211-216.  
(Lin Dan, Li Min-qiang, Kou Ji-song. Two methods to prevent and overcome premature convergence in evolutionary programming [J]. J of Systems Engineering, 2001, 16(3): 211-216.)
- [5] 李孝安, 康继昌. 一种新的快速进化规划方法[J]. 西北工业大学学报, 2001, 19(1): 11-14.  
(Li Xiao-an, Kang Ji-chang. An improved fast evolutionary programming [J]. J of Northwestern Polytechnical University, 2001, 19(1): 11-14.)
- [6] 郭崇慧, 唐焕文. 一种改进的进化规划算法及其收敛性[J]. 高等学校计算数学学报, 2002, 24(1): 51-56.  
(Guo Chong-hui, Tang Huan-wen. An improved evolutionary programming algorithm and its convergence analysis [J]. Numerical Mathematics J of Chinese Universities, 2002, 24(1): 51-56.)
- [7] 黄席樾. 现代智能算法理论及应用[M]. 北京: 科学出版社, 2005.  
(Huang Xi-yue. Modern intelligent algorithms theory and applications[M]. Beijing: Science Press, 2005.)
- [8] 王磊, 潘进, 焦李成. 免疫规划[J]. 计算机学报, 2000, 23(8): 806-812.  
(Wang Lei, Pan Jin, Jiao Li-cheng. The immune programming[J]. Chinese J of Computers, 2000, 23(8): 806-812.)
- [9] 付利华, 何华灿. 基于免疫进化规划的一种柔性神经模糊推理系统[J]. 计算机工程与应用, 2004, 40(18): 19-22.  
(Fu Li-hua, He Hua-can. A flexible neuro-fuzzy inference system based on immune evolutionary programming [J]. Computer Engineering and Application, 2004, 40(18): 19-22.)
- [10] Chellapilla K, Fogel D. Two new mutation operators for enhanced search and optimization in evolutionary programming[C]. Proc of SPIE. Bellingham: SPIE Press, 1997: 260-269.
- [11] 林丹, 李敏强, 寇纪淞. 进化规划和进化策略中变异算子的若干研究[J]. 天津大学学报, 2000, 33(5): 627-630.  
(Lin Dan, Li Min-qiang, Kou Ji-song. On research of mutation operator in evolutionary programming and evolutionary strategies [J]. J of Tianjin University, 2000, 33(5): 627-630.)
- [12] 王向军, 向东. 一种双种群进化规划算法[J]. 计算机学报, 2006, 29(5): 835-840.  
(Wang Xiang-jun, Xiang Dong. A novel bi-group evolutionary programming [J]. Chinese J of Computers, 2006, 29(5): 835-840.)
- [13] 何大阔, 王福利. 一种提高遗传算法全局收敛性的方法[J]. 东北大学学报(自然科学版), 2003, 24(6): 511-514.  
(He Da-kuo, Wang Fu-li. Improving the global convergence of the genetic algorithm [J]. J of Northeastern University (Natural Science), 2003, 24(6): 511-514.)
- [14] Xin Yao. Evolutionary programming made faster[J]. IEEE Trans on Evolutionary Computation, 1999, 3(2): 82-102.

(上接第 1410 页)

- [4] 刘党辉, 沈兰荪, Kir-man Lam. 人脸检测研究进展[J]. 计算机工程与应用, 2003, 39(28): 5-9.  
(Liu Dang-hui, Shen Lan-sun, Kir-man Lam. Face detection: A survey [J]. Computer Engineering and Applications, 2003, 39(28): 5-9.)
- [5] 赵丽红, 刘纪红, 徐心和. 人脸检测方法综述[J]. 计算机应用研究, 2004, (9): 1-5.  
(Zhao Li-hong, Liu Ji-hong, Xu Xin-he. A survey of human face detection [J]. Application Research of Computers, 2004, (9): 1-5.)
- [6] 梁路宏, 艾海舟, 徐光祐, 等. 人脸检测研究综述[J]. 计算机学报, 2002, (5): 41-42.  
(Liang Lu-hong, Ai Hai-zhou, Xu Guang-you, et al. A survey of human face detection [J]. Chinese J of Computers, 2002, (5): 41-42.)
- [7] 甘俊英, 张有为. 一种基于奇异值特征的神经网络人脸识别新途径[J]. 电子学报, 2004, (1): 170-173.  
(Gan Jun-ying, Zhang You-wei. A new approach for face recognition based on singular value features and neural networks [J]. Acta Electronica Sinica, 2004, (1): 170-173.)
- [8] 周洁, 卢春雨, 张长水, 等. 人脸自动识别方法综述[J]. 电子学报, 2000, 28(4): 102-106.  
(Zhou Jie, Lu Chun-yu, Zhang Chang-shui, et al. A survey of automatic human face recognition [J]. Acta Electronica Sinica, 2000, 28(4): 102-106.)
- [9] 刘直芳, 王运辉. 数字图像处理与分析[M]. 北京: 清华大学出版社, 2006.  
(Liu Zhi-fang, Wang Yun-hui. Digital image processing and analysis [M]. Beijing: Tsinghua University Press, 2006.)