

一种新的变异因子选择策略

王帅群¹ 敖日格乐² 高尚策³ 唐 政² 马海英¹

(同济大学电子与信息工程学院 上海 201804)¹ (日本富山大学工学院 富山 930-8555)²

(东华大学信息科学与技术学院 上海 201620)³

摘 要 在具有多层学习机制的免疫优化算法中,变异因子的选择概率对算法的有效性起着至关重要的作用。如果选择不够合理,将导致算法容易陷入局部最优,在一定程度上影响解的质量和收敛速度。针对多层学习机制的特点,讨论了各个因子之间的依赖性和相关性,提出了一种新的变异因子选择策略。选择4个基准函数作为测试函数进行了验证,结果表明,解的质量和收敛速度都有了明显的改善。

关键词 多层学习机制,高斯变异,柯西变异,Lateral变异,Baldwinian变异

中图分类号 TP391 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2014.09.042

New Strategy Based on Selection of Mutation Operator

WANG Shuai-qun¹ Ao-ri-ge-le² GAO Shang-ce³ TANG Zheng² MA Hai-ying¹

(College of Electronics & Information Engineering, Tongji University, Shanghai 201804, China)¹

(Faculty of Engineering, University of Toyama, Toyama 930-8555, Japan)²

(College of Information Science and Technology, Donghua University, Shanghai 201620, China)³

Abstract In immune optimization algorithm with multi-learning mechanism, the selection probability of mutation operators plays a vital role in the effectiveness of the algorithm. If the choice is not appropriate, the algorithm is easy to fall into local optimum, to a certain extent, affects the quality of the solution and reduces the rate of convergence. According to the characteristics of the multi-learning mechanism, the dependence and correlation between mutation operators were discussed. A new mutation operator selection strategy was proposed and four benchmark functions were selected as test functions to verify the performance of the strategy. The result shows that the quality of the solution and the convergence speed have obvious improvement.

Keywords Multi-learning mechanism, Gaussian mutation, Cauchy mutation, Lateral mutation, Baldwinian mutation

1 引言

自然启发的算法包括进化算法、粒子智能、人工免疫系统 and 模拟退火等,已经依据其解决复杂问题的潜力而受到广泛的关注^[1,2]。人工免疫系统(AIS)是受生物免疫系统理论和模型启发的,它模拟生物免疫反应机制,描绘免疫系统受抗原侵犯、抗体识别抗原的过程。最常用的生物免疫反应机制包括克隆增殖^[3]、否定选择^[4]、免疫网络^[5]、危险理论^[6]、树突细胞模型^[7]等。人工免疫系统已经成功地应用于多种复杂问题,比如旅行商问题^[8]、自动聚类^[9]、模式识别^[10]、绘图问题^[11]、机器人控制^[12]和数字优化问题^[13]等。

免疫算法由代表问题可行解的抗体种群组成,抗体的适应度反映了抗体解决问题的优劣。免疫算法主要依靠克隆、变异和选择3个过程来寻找问题的最优解。在免疫算法中,克隆增殖是依据抗体的适应度,较高适应度的抗体将被复制

得较多;在变异过程,抗体后代的产生通常是应用随机学习因子;较高适应度的抗体将被选择进入下一代。尽管免疫算法在解决复杂优化问题上已经展现出优势,但是其性能受问题维度和峰值的限制,因此免疫算法像其他的优化算法一样,存在搜索停滞、未成熟先收敛、陷入局部最优和收敛速度慢等问题^[14]。

为了解决免疫算法中存在的问题,很多学者提出了一系列改进的AIS。通过修改抗体的表示方式,Jiao^[15]提出了量子编码的AIS,利用量子旋转门来避免未成熟先收敛。为了解决参数的调整问题,Garrett^[16]提出了无参数的AIS,种群大小、克隆和变异数目等参数都被去掉。为了提高全局最优和局部最优的平衡,特别是为了让抗体尽可能地达到没有探索到的区域,提出了注射疫苗的AIS^[17]。为了加快抗体的收敛速度,提出了基于聚类和梯度的AIS^[18]。通过改变变异操作来提高群体的多样性,逃离局部最优,Nitesh Khilwani^[19]将高斯

到稿日期:2013-12-01 返修日期:2014-03-03 本文受国家自然科学基金项目(61203325),上海市教育发展基金会晨光计划项目(12CG35),中国教育部博士点基金(20120075120004),中央高校基本科研业务费专项资金(13D110416),南通市科技计划项目(BK2013050)资助。

王帅群 博士生,主要研究方向为模式识别与智能系统、人工免疫系统、问题优化,E-mail: wangshuaiqun08@gmail.com;敖日格乐 博士生,主要研究方向为人工免疫系统;高尚策 副教授,硕士生导师,主要研究方向为人工免疫系统、人工神经网络;唐 政 教授,博士生导师,主要研究方向为智能信息技术、人工神经网络、免疫优化;马海英 女,博士生,讲师,主要研究方向为智能算法、密码学和网络安全。

变异和柯西变异结合运用到克隆算法中;王帅群、高尚策^[20]等在免疫算法中引入多层学习机制,它可以互补各个变异因子的不足,从而提高算法的收敛速度和解的质量。但是变异因子的选择概率对算法的性能起着至关重要的作用,仅通过单纯性重心实验设计法确定的因子选择概率,并不一定是最佳变异因子选择概率值,从而影响了算法的性能,不过该文中的实验数据足以表明多层学习机制的优势。在本文中,我们提出了一种新的变异因子概率确定机制,该机制是在多层学习机制中,深入研究两两变异因子的相关性和依赖性,从而分配一个概率比值。该准则依赖于对整个实验的结果具有较大贡献的变异因子,则分配较大的概率,符合自然界的规律。

2 多层学习机制

多层学习机制,就是将多种不同搜索动力学的变异因子嵌入到抗体进化过程中,从而更好地控制“探索”和“开采”之间的平衡,提高免疫算法的学习能力,促使种群中的抗体快速成熟。多层学习机制的一般框架图如图1所示, $M=1,2,\dots,n$,各因子之间是并行的,从而互补了各因子之间的不足。




图1 多层学习机制的框架

2.1 多层学习机制中的变异因子确定机制

在多层学习机制中,变异因子的选择是非常重要的,依据3个准则:

- (1)该变异因子在免疫领域的应用比较广泛,并且已经证明是比较有效的。
- (2)选择一些比较简单、容易执行的变异因子。
- (3)变异因子具有不同的搜索动力学特性。

2.2 多层学习机制中的变异因子选择

在上述准则的指导下,多层学习机制选择高斯变异、柯西变异、Lateral变异和Baldwinian变异4个因子,下面将简单介绍这4个变异因子。为了介绍方便,种群由 $\{X_1, \dots, X_N\}$ 表示,抗体由 $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$ 表示,其中 N 代表种群中的抗体数目, D 代表优化问题的维度,执行变异后的种群由 $\{X_1', X_2', \dots, X_N'\}$ 表示。

$$\{X_1', X_2', \dots, X_N'\} = L\{X_1, X_2, \dots, X_N\}, L \in \{GM, CM, LM, BL\} \quad (1)$$

高斯变异(Gaussianmutation, GM)具有两个参数:均值 μ 和方差 σ ,它们共同决定着变异的步长。均值为 μ 和方差为 σ 的一维高斯密度函数为:

$$f_{gau}(x) = \frac{1}{\sigma \sqrt{2\pi}} \exp \left(-\frac{(x-\mu)^2}{2\sigma^2} \right) \quad (2)$$

在大部分的研究中,通常将高斯变异策略简化为基于原

点的高斯密度函数,即 $\mu=0, \sigma=1$,高斯变异的执行过程如下:

$$x'_{ij} = x_{ij} + s_g N_j(0, 1) \quad (3)$$

$N_j(0, 1)$ 是均值为0、方差为1的正态分布高斯随机数,符号 i 表示抗体在种群中的序号, j 代表维度, s_g 是变异的步长:

$$s_g = \text{random}(+, -) \sqrt{2 \ln(w_g \sqrt{2\pi})} \quad (4)$$

w_g 是在区间 $[0, f_{gau}(0)]$ 中均匀产生的随机数。

柯西变异(Cauchymutation, CM)是基于柯西密度函数的,关于原点对称的一维柯西密度函数为:

$$f_{cauchy}(x) = \frac{1}{\pi} \frac{1}{1+x^2} \quad (5)$$

柯西分布最重要的特性是期望不存在,柯西密度函数的图像和高斯密度函数的图像非常相似,但是其达到 x 轴的速度非常慢,柯西变异的执行过程如下:

$$x'_{ij} = x_{ij} + s_c \delta_j \quad (6)$$

$$s_c = \text{random}(+, -) \sqrt{\frac{1}{w_c \pi} - 1} \quad (7)$$

δ_j 是柯西随机变量, s_c 是柯西变异的步长, s_c 是在区间 $[0, f_{cauchy}(0)]$ 中均匀产生的随机数。

Baldwinian变异(BL)是利用不同个体之间的信息差异将等位上的信息进行进化,学习过程如下:

$$x_{ij} = \begin{cases} x_{ij} + s \cdot (x_{pj} - x_{qj}), & \text{if } \text{rand} \leq P \\ x_{ij}, & \text{otherwise} \end{cases} \quad (8)$$

$p, q \in \{1, 2, \dots, n\}, p \neq q \neq i, s$ 是学习强度, $\text{rand}()$ 是 $[0, 1]$ 之间的均匀随机数, $P \in (0, 1]$ 控制着Baldwinian的学习概率,通常取0.8。

Lateral变异(LM)的执行过程如下:

$$x'_{ij} = (1-\alpha) * x_{ij} + \alpha * x_{kj} \quad (9)$$

其中, $k \in \{1, 2, \dots, N\}$ 且 $k \neq i, \alpha \in (0, 1)$ 随机数。

2.3 多层学习机制算法

多层学习机制算法执行流程如表1所列, $prob_{LM}, prob_{BL}, prob_{GM}$ 和 $prob_{CM}$ 分别表示Lateral变异、Baldwinian变异、高斯变异和柯西变异的选择概率, R 为 $(0, 1)$ 之间的均匀随机数,并且4个概率满足如下等式:

$$prob_{LM} + prob_{BL} + prob_{GM} + prob_{CM} = 1 \quad (10)$$

表1 多层学习机制执行算法

算法开始:输入抗体 X_i ;
初始化 $prob_{LM}, prob_{BL}, prob_{GM}, prob_{CM}, R = \text{rand}()$;
If $0 < R < prob_{LM}$
执行 Lateral 变异;
Else If $0 < R < prob_{LM} + prob_{BL}$
执行 Baldwinian 变异;
Else if $0 < R < prob_{LM} + prob_{BL} + prob_{GM}$
执行高斯变异;
Else 执行柯西变异;
End If
算法结束:输出变异后的抗体 X_i' ;

3 变异因子概率确定机制

将“贡献较大的个体,分配较多的资源”这种社会现象,映射到多层学习机制中的变异因子的选择上。根据两两变异因子的结合,可以得到每两个变异因子之间的依赖性和相关性,同时得到其对优化问题解的贡献大小,因而确定了其参与种

群优化的概率,实验结果提高了算法的全局优化能力和收敛速度。不同于依据单纯性重心实验设计法和经验理论指导的多层学习机制免疫算法,本文是将4个变异因子两两结合,组成 C_n^2 组实验,每组实验是两个变异因子不同概率的组合。

在多层学习机制的免疫算法中,变异因子可以有很多个,这里设为 $M=1,2,\dots,n$ 。在文献[1]中,仅根据单纯性重心实验设计法得到每个变异因子的选择概率:

$$prob_i = a_i + b \quad (11)$$

a_i 为单纯性重心实验设计法中得到的最优解的那组变异因子的参与概率, b 为该数值附近的一个扰动,通常取 $b \in (-0.1, 0.1)$ 。该概率决定着每个变异因子在优化过程中的参与机会,很大程度上影响着算法的性能。本文将对得到最优解的那组作为优先考虑的对象,因为其对算法的性能贡献最大,依据这种思想,在标准集函数上进行了验证,给出了概率确定公式:

$$prob_{first} = prob_{best}^{small} \quad (12)$$

$$\sum_{i=second}^n prob_i = 1 - prob_{first} = prob_{best}^{small} \quad (13)$$

$$MOperator_{second} = MOperator_{best}^{small} \quad (14)$$

$$prob_{second} = prob_{best}^{small} * \sum_{j=1}^{n-2} prob_{second}^j / (n-2) \quad (15)$$

$$prob_j = prob_{best}^{small} * prob_{second}^j / (n-2), j=1, 2, \dots, n-2 \quad (16)$$

$prob_{best}^{small}$ 为 C_n^2 组实验中最优解,变异因子的参与概率较大,该变异因子也是优先被确定的,其概率表示为 $prob_{first}$,其余所有因子的参与概率之和为 $prob_{best}^{small}$ 。第二个被确定的变异因子是最优解中参与概率较小的变异因子,记为 $MOperator_{second}$,其概率由式(14)确定, n 为多次学习机制中的变异因子数目,除最优解中两个变异因子之外的其他变异因子的概率由式(16)确定。

4 算法测试及结果分析

表2为测试函数集,选择了2个单峰值函数 f_1 和 f_2 ,2个多峰值函数 f_3 和 f_4 。为了与用单纯性重心实验设计方法确定的概率的多层学习机制免疫算法进行比较,本文运用相同的变异因子,即GM、CM、LM和BL,同时参数设置一样,算法抗体种群数目为30,独立运行30次,算法终止条件迭代次数为2000。首先在函数1中,对4个变异因子两两结合进行验证,得到变异因子之间的不同概率比例组合优化解图,如图2所示,横坐标为两因子之间的概率组合,纵坐标为解的质量。通过该图不难发现,LM和BL结合后得到的解的质量最优,并且LM的比重较大,因此LM因子对算法的贡献最大, $prob_{first} = 0.9$,第一个被确定的变异因子为LM,第二个被确定的变异因子为BL,其他的变异因子的概率可由式(12)一式(15)求得,因此得到一组概率组合,如表3中的Group4所列。

表3给出了4组典型的变异因子概率组合,Group1、Group2、Group3中CM、GM的概率完全相同,Group1中LM的概率小于BL,Group2中LM的概率等于BL,也是文献[1]中的参数取值,Group3中LM的概率大于BL,Group4是我们提出的机制得到的概率组合。

表2 测试函数集

Testfunction	n	S	f_{min}
$f_1(x) = \sum_{i=1}^n x_i^2$	30	$[-100, 100]^n$	0
$f_2(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	30	$[-10, 10]^n$	0
$f_3(x) = -20 \exp(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}) - \exp(\frac{1}{n} \sum_{i=1}^n \cos 2\pi x_i) + 20 + e$	30	$[-32, 32]^n$	0
$f_4(x) = \frac{\pi}{n} \{ 10 \sin^2(\pi y_1) + \sum_{i=1}^{n-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi y_{i+1})] + (y_n - 1)^2 \} + \sum_{i=1}^n \mu(x_i, 10, 100, 4)$ $y_i = 1 + \frac{1}{4} (x_i + 1)$ $\mu(x_i, a, k, m) = \begin{cases} k(x_i - a)^m, & x_i > a \\ 0, & -a \leq x_i \leq a \\ k(-x_i - a)^2, & x_i < -a \end{cases}$	30	$[-50, 50]^n$	0




图2 变异因子两两结合解的收敛图

表3 4组概率组合表

prob	Group1	Group2	Group3	Group4
LM	0.2	0.4	0.6	0.9
BL	0.6	0.4	0.2	0.05
CM	0.1	0.1	0.1	0.025
GM	0.1	0.1	0.1	0.025

表4是4组不同的概率组合在4个测试函数上进行验证的统计结果,通过4组概率取值的均值和方差比较表明,基于两两因子的相关性和依赖性确定的变异因子参与概率明显优于其他3组,Group1是与本文提出的观点最不一致的一组,即BL的参与概率大于LM的参与概率,因此其效果也最差。Group2即是文献[1]中的概率取值,其均值和方差也明显优于Group1、Group3中概率取值虽然符合LM因子大于BL因子,其效果也明显优于Group1和Group2,但是其效果却不如Group4。Group4是根据本文新提出来的方法确定的概率取值,其解的质量是最好的。

表4 4组不同概率实验结果

Mean±Std	f_1	f_2
Group1	9.81E-24±9.55E-24	1.75E-11±1.02E-11
Group2	4.87E-33±8.43E-33	1.90E-14±1.35E-14
Group3	3.16E-36±6.29E-36	7.64E-22±9.34E-22
Group4	2.86E-44±3.88E-44	1.91E-26±8.49E-27
Mean±Std	f_3	f_4
Group1	4.00E-15±0.00E+00	3.82E-27±5.31E-27
Group2	4.00E-15±0.00E+00	2.36E-32±0.00E+00
Group3	4.00E-15±0.00E+00	2.36E-32±0.00E+00
Group4	4.00E-15±0.00E+00	2.36E-32±0.00E+00




图3 4组经典概率组合平均收敛图和解的质量图

LM运用了个体之间的学习信息,特别是当指导抗体趋近于全局最优值时,该因子可以加快收敛速度;BL是在自身的基础上,更有效地利用了个体差异,可以更快地向较优的抗体靠近;但是这两个变异因子都容易使所有的抗体最终收敛于一个局部最优解;高斯变异和柯西变异正好克服了这一缺点,可以使抗体跳出局部最优值,两个变异因子的互补优势明显要优于每一个因子。很多学者对柯西变异和高斯变异的结合做了研究和验证,其优势是加快了收敛速度,避免了陷入局部最优。在单峰值函数 f_1 和 f_2 中,该机制确定的变异因子选择概率组合,无论是在收敛的速度还是在最优解的获得值上,都得到了明显的改善。但是对于多峰值函数,局部峰值较多,所以算法容易陷入局部最优,因为高斯变异和柯西变异的概率较小,因此该组合虽然没有避免陷入局部最优,但是收敛速度明显提高。

结束语 本文提出了一种新的变异因子选择概率确定机制,其有效性已通过收敛速度和解的质量在单峰值函数和多峰值函数上得到了验证。在多峰值函数上虽然其收敛速度加快了,但是解的质量并没有明显的改善。在进一步的工作中,将概率设置为动态自适应的,在优化的后期,加大柯西变异因子的概率比值,使多峰值函数解的质量进一步改善。多层学习机制的思想不仅可以应用在免疫算法中,也适用于其他自然启发的算法,可以将其进一步扩展。

参考文献

[1] de Castro L N. Fundamentals of natural computing: an overview

[J]. Physics of Life Reviews, 2007, 4(1): 1-36

- [2] Worden K, Staszewski W J, Hensman J J. Natural computing for mechanical systems research: A tutorial overview[J]. Mechanical Systems and Signal Processing, 2011, 25(1): 4-111
- [3] Burnet M. The clonal selection theory of acquired immunity [M]. Nashville: Vanderbilt University Press, 1959, 3: 1-6
- [4] Nossal G J V. Negative selection of lymphocytes[J]. Cell, 1994, 76(2): 229-239
- [5] Perelson A S. Immune network theory [J]. Immunological Reviews, 1989, 110(1): 5-36
- [6] Matzinger P. The danger model: a renewed sense of self[J]. Science, 2002, 296(5566): 301-305
- [7] Gu F, Greensmith J, Aickelin U. Theoretical formulation and analysis of the deterministic dendritic cell algorithm[J]. Biosystems, 2013, 111(2): 127-135
- [8] Gao S, Wang W, Dai H, et al. Improved clonal selection algorithm combined with ant colony optimization[J]. IEICE transactions on information and systems, 2008, 91(6): 1813-1823
- [9] Liu R, Jiao L, Zhang X, et al. Gene transposon based clone selection algorithm for automatic clustering [J]. Information Sciences, 2012, 204: 1-22
- [10] Dudek G. An Artificial Immune System for Classification with Local Feature Selection[J]. IEEE Transactions on Evolutionary Computation, 2012, 16(6): 1
- [11] Gao S, Wang R, Tamura H, et al. A Multi-Layered Immune System for Graph Planarization Problem[J]. IEICE transactions on information and systems, 2009, 92(12): 2498-2507
- [12] Whitbrook A M, Aickelin U, Garibaldi J M. Idiotypic immune networks in mobile-robot control [J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics, 2007, 37(6): 1581-1598
- [13] de Mello Honório L, Leite da Silva A M, Barbosa D A. A cluster and gradient-based artificial immune system applied in optimization scenarios[J]. IEEE Transactions on Evolutionary Computation, 2012, 16(3): 301-318
- [14] Yao X, Xu Y. Recent advances in evolutionary computation[J]. Journal of Computer Science and Technology, 2006, 21(1): 1-18
- [15] Jiao L, Li Y, Gong M, et al. Quantum-inspired immune clonal algorithm for global optimization[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics, 2008, 38(5): 1234-1253
- [16] Garrett S M. Parameter-free, adaptive clonal selection [C]// CEC. 2004: 1052-1058
- [17] Woldemariam K M, Yen G G. Vaccine-enhanced artificial immune system for multimodal function optimization [J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics, 2010, 40(1): 218-228
- [18] de Mello Honório L, Leite da Silva A M, Barbosa D A. A cluster and gradient-based artificial immune system applied in optimization scenarios[J]. IEEE Transactions on Evolutionary Computation, 2012, 16(3): 301-318
- [19] Khilwani N, Prakash A, Shankar R, et al. Fast clonal algorithm [J]. Engineering Applications of Artificial Intelligence, 2008, 21(1): 106-128
- [20] Wang S, Gao S, Aorigele, et al. A Multi-learning Immune Algorithm for Numerical Optimization [J]. IEICE transactions on FUNDAMENTALS, 2013