

一类具有精英学习能力的增强型人工免疫网络优化算法研究

李中华, 张雨浓, 谭洪舟, 陈卓怡

(中山大学 信息科学与技术学院, 广东 广州 510275)

摘要: 本文提出了一种用于求解优化问题的具有精英学习能力的增强型人工免疫网络(EaiNet-EL)算法. 该算法集成了亲和力学习和精英学习, 并采用两个控制因子分别调节其学习速度. 本文对控制因子的灵敏度作了探讨, 并在两个经典函数的优化实验中将提出的EaiNet-EL算法同传统aiNet算法作了比较研究. 实验结果表明, EaiNet-EL在最优解质量和收敛速度上都优于传统aiNet算法. 作为应用实例, 工业PID控制器被用于测试EaiNet-EL算法的性能. 实验所得的阶跃响应曲线说明, 使用EaiNet-EL得到的系统性能要优于使用其它三种方法得到的系统性能.

关键词: 人工免疫系统; 精英学习; 亲和力学习; 微粒群优化; PID控制

中图分类号: TP273 **文献标识码:** A

An Enhanced Artificial Immune Network with Elitist-Learning Functionality for Optimization Problems

LI Zhong-hua, ZHANG Yu-nong, TAN Hong-Zhou, CHEN Zhuo-yi

(School of Information Science and Technology, Sun Yat-sen University, Guangzhou Guangdong 510275, China)

Abstract: This paper proposed an new enhanced artificial immune network with elitist-learning (EaiNet-EL) for optimization problems. The proposed new algorithm introduces two types of learning mechanisms, affinity-learning and elitist-learning, which are respectively adjusted by two weighted control factors. The sensitivity of factor values is investigated and the comparative experiments are carried out between the proposed EaiNet-EL optimization and the canonical aiNet optimization on two classical benchmarks. The simulation results indicate that the proposed EaiNet-EL optimization outperforms the canonical aiNet optimization in both the final solution and convergence speed. Furthermore, a typical application — an industrial PID control system, is considered to test the performances of multiple optimization approaches including the proposed EaiNet-EL optimization. The step response of the control system shows better performance occurs under the proposed EaiNet-EL optimization than that under other three approaches.

Key words: artificial immune network; elitist-learning; affinity-learning; particle swarm optimization; PID controller

1 引言 (Introduction)

近年来, 许多学者致力于模拟人体免疫系统建立人工模型, 来解决复杂的理论和工程问题, 如函数优化、异常检测、模式识别、计算机安全、机器学习、控制工程、数据聚类等^[1~8]. 这些特殊的机制主要包括识别(自体/非自体)、克隆复制、成熟变异、选择记忆, 甚至来自遗传系统的交叉操作等. 为简单起见, 本文将所有以人体免疫系统生物机理为基础建立的人工模型统称为人工免疫系统^[1].

同遗传算法一样, 人工免疫系统也被大量用于

优化问题. 根据人体免疫系统的进化理论, de Castro提出了人工免疫网络模型(aiNet), 并为解决多模态函数优化问题作了改进, 即后来的opt-aiNet或传统aiNet优化算法^[2]. 实验证明, 传统aiNet算法对于亲和力域有很强的组合搜索能力, 而且抗体群的稳定性很好. 后来, 传统aiNet算法被用于如交通流分析、数据聚类、电磁优化等诸多领域. 鉴于传统aiNet算法在很大程度上依赖于初始参数, 文献^[9]对亲和力阈值、相似度阈值等几个参数做了研究, 提出了基于参数优化的自适应人工免疫算法. 文

献[10]在改进算法中引入一个新的可调参数—与进化代数成反比的候选抗体搜索半径,作者声明该算法可以很快的速率找到最优解.文献[11]尝试将免疫系统和遗传系统结合,得到免疫遗传算法,并验证了算法的有效性.以上研究都表明,无论在科学领域还是工程领域,人工免疫系统都是一个研究热点.

本文提出具有精英学习能力的增强型人工免疫网络算法(EaiNet-EL),用于解决优化问题.源自微粒群优化的精英学习,即每个独立的抗体总是向抗体群中最优秀的抗体学习,从而提高EaiNet-EL优化算法的收敛速度.EaiNet-EL优化算法注重自身进化(或亲和力学习)和精英学习之间的平衡,其对应的加权因子可用于控制EaiNet-EL算法的优化效果.

2 相关基础理论 (Reviews of related theories)

2.1 免疫系统 (Immune systems)

人体免疫系统负责监测外来病原的入侵,并消灭它们,以保护人体的健康.由骨髓分泌的B细胞流经淋巴循环系统.一旦发现抗原入侵,B细胞就会通过一系列的生化反应来产生抗体以消灭抗原.抗体和抗原的匹配关系可用术语亲和力来表述^[1].亲和力越大,则刺激水平越高;反之亦然.而抗体间的刺激与抑制,保证了抗体和抗原匹配的多样性.刺激和抑制的强度由抗体的浓度或相似度决定.当刺激达到一定程度时,抗体将趋于成熟,复制与变异就会大量发生.其中,大部分的抗体将分化成浆细胞,其余的则会变成记忆细胞.当抗原被消灭后,成熟B细胞的浓度将因为抑制作用而慢慢退回到正常水平.

类似于遗传算法,人工免疫算法将待解决的目标问题看作抗原,而将可行解看作候选抗体^[2].亲和力函数被用来计算候选抗体与抗原的匹配程度.一个完整的免疫进化过程包括选择、克隆、变异、保持和死亡.随着进化演变,就会得到一个或几个拥有最高亲和力的抗体,即目标问题的最优解.不难想象,随着人们对免疫系统有更深入的理解,将有更多的人工免疫系统模型出现.其中,最基本的是传统人工免疫系统.设 $Ab(t) \in R^{N \times n}$ 是候选解的抗体群, $Ab_i(t)$ 是其中的一个抗体,对于第 t 代抗体:

$$Ab(t) = \{Ab_1(t), Ab_2(t), \dots, Ab_N(t)\}, \quad (1)$$

其中 N 是候选抗体的总数,而 n 是抗体的长度,最优解记作 $Ab^* \in R^n$.亲和力计算函数 $aff(\cdot)$ 由目标问题或变量决定,而候选抗体间的相似度 $sim(\cdot)$ 由连续域内的欧几里德距离度量.其算法执行步骤如下:

Step 1. 置抗体代数 $t=0$,并初始化抗体群 $Ab(t)$.

Step 2. 对于每代抗体 $Ab_i(t)$,执行以下的操作:

Step 2.1. 亲和力计算.根据亲和力函数计算每个抗体 $Ab_i(t)$ 的亲和力 $aff(Ab_i(t))$.

Step 2.2. 克隆操作.根据 $Ab_i(t)$ 的亲和力大小克隆抗体子群 $Ab_i^*(t)$.亲和力越大, $Ab_i(t)$ 克隆个数越多;反之亦然.

Step 2.3. 变异操作.抗体子群 $Ab_i^*(t)$ 的变异度同样取决于父抗体的亲和力,从而得到新的抗体子群 $Ab_i^{**}(t)$.变异程度同父抗体的亲和力成反比.父抗体的亲和力越大,则变异度越小;反之亦然.

Step 2.4. 选择操作.选择 $Ab_i^{**}(t)$ 中亲和力高的抗体进入子代抗体群 $Ab(t+1)$.

Step 3. 抑制操作.根据 $Ab(t+1)$ 中抗体的相似度,删除冗余抗体.同时随机补充一些新抗体加入到 $Ab(t+1)$ 中,以保持候选抗体群的多样性.

Step 4. 若未满足终止条件,则 $t=t+1$,并返回**Step 2**.否则,输出亲和力最高的抗体作为最优解.

2.2 微粒群优化 (Particle swarm optimization)

微粒群优化算法(PSO)是一个基于粒子群的搜索算法,其灵感来自种群活动和社会规范^[12,13].PSO不仅强调粒子的自身学习,而且注重向邻近精英粒子学习.在搜索过程中,粒子有飞向更优位置的趋势.

假设粒子群有 Q 个粒子分布在 l 维的搜索区域内,即 $S \in R^l$.第 i 个粒子用 l 维向量表示,即 $X_i = (x_{i1}, x_{i2}, \dots, x_{il})' \in S$.该粒子的速度也可用一个 n 维向量表示,即 $V_i = (v_{i1}, v_{i2}, \dots, v_{il})'$.第 i 个粒子的最佳位置是 S 内的一点,记作 $P_i = (p_{i1}, p_{i2}, \dots, p_{il})'$.设 g 表示所有粒子历经的最优位置, t 表示迭代次数.因此,根据标准的PSO理论,粒子群的速度和位置可更新如下:

$$\begin{cases} V_i(t+1) = V_i(t) + c_1 r_1 (P_i(t) - X_i(t)) \\ \quad + c_2 r_2 (P_g(t) - X_i(t)) \\ X_i(t+1) = X_i(t) + V_i(t+1) \end{cases} \quad (2)$$

其中 c_1 和 c_2 是正的常数,称为加速度常数, r_1 和 r_2 是 $[0, 1]$ 间的随机数.在式(2)中,相比 $V_i(t)$, $V_i(t+1)$ 增加了两项: $c_1 r_1 (P_i(t) - X_i(t))$ 和 $c_2 r_2 (P_g(t) - X_i(t))$.前者旨在引导粒子向着最佳位置移动;而后者强化向最优粒子的学习,并趋于逼近最优粒子.因此,粒子们总是在竞争成为新的最优粒子.

3 带精英学习能力的EaiNet-EL优化 (The EaiNet-EL optimization with elitist-learning)
在传统aiNet优化算法中,将抗原定义为目标问

题, 而将抗体定义为问题的候选可行解^[3]. 一方面, 候选抗体的进化取决于抗体与抗原之间的亲和力. 在克隆操作中, 抗体的克隆倍数被预先设定, 而不是由亲和力决定(作者认为, 克隆倍数应该同父抗体的亲和力成正比). 在变异操作中, 每个抗体的变异程度与父抗体的亲和力成反比.

另一方面, aiNet将所有的候选抗体群看作是一个免疫网络. 细胞之间的相互作用, 称为内部细胞作用. 如果两个网络细胞在某个空间内距离很近, 即两

个抗体间的亲和力低于设定的抑制阈值, 就会触发相应的抑制操作. 经抑制后留存的网络细胞成为记忆细胞, 有更高的亲和力和适应性.

图1左半部分给出了传统aiNet算法的流程图, 主要由初始化操作、亲和力评价、选择克隆、变异操作、抗体筛选、抗体抑制和随机更新七个模块. 候选抗体的变异操作可通过下式来计算:

$$\begin{cases} Ab_{ij}(t+1) = Ab_i(t) + \frac{\gamma}{\beta} e^{-aff(Ab_i(t))} \\ Ab_i(t) = \arg \max_{1 \leq j \leq N_c} aff(Ab_{ij}(t)) \end{cases} \quad (3)$$

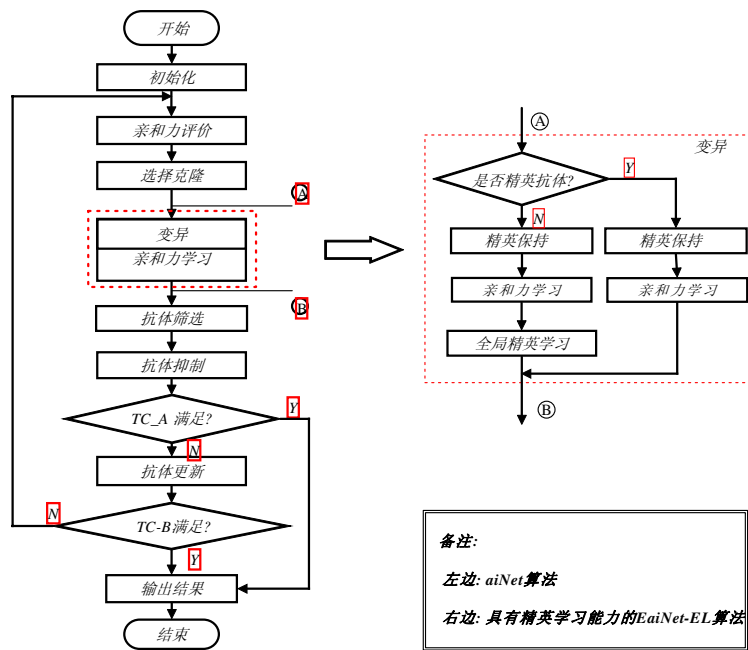


图1 人工免疫系统的流程图

Fig.1 The Flowchart of artificial immune system (for both aiNet and EaiNet-EL)

其中 t 表示抗体代数, $Ab_i(t)$ 是变异前的第 i 个候选抗体, $Ab_{ij}(t+1)$ 是从第 i 个父抗体变异得到的第 j 个抗体, $aff(Ab_i(t))$ 是与 $Ab_i(t)$ 对应的归一化亲和力函数, β 是变异控制参数, 而 r 是(0,1)间的随机数, N_c 是每个抗体的克隆倍数.

为保证找到全局最优解, 传统aiNet算法设有两个终止条件^[2]: 一个是相邻两代抗体的平均亲和力不再发生变化或者变化非常微小, 称为终止条件A(TC-A); 另一个是算法的迭代数已经达到预设值, 称为终止条件B(TC-B). 只要满足上述的任何条件, 算法都会停止计算, 并输出全局最优解.

为改进aiNet的性能, 本文提出一种带有精英学习能力的增强型人工免疫网络优化(EaiNet-EL)算法, 其改进之处如图1的右半部分. 具体而言是, 在变异操作中, 有选择性地对待精英抗体和非精

英抗体. 对于精英抗体, 根据亲和力执行精英保持及亲和力学习策略; 而对于非精英抗体, 除了执行精英保留及亲和力学习策略外, 还要执行精英学习策略. 因此, 对于EaiNet-EL变异操作(如图1的红色虚线框部分), 可按下面的公式进行:

当 $Ab_g(t) \neq Ab_i(t)$ 时,

$$Ab_{ij}(t+1) = Ab_i(t) + \frac{c_1 r_1}{\beta} e^{-aff(Ab_i(t))} + c_2 r_2 (Ab_g(t) - Ab_i(t)); \quad (4)$$

当 $Ab_g(t) = Ab_i(t)$ 时,

$$Ab_{ij}(t+1) = Ab_i(t) + \frac{c_1 r_1}{\beta} e^{-aff(Ab_i(t))}. \quad (5)$$

其中,

$$Ab_i(t) = \arg \max_{1 \leq j \leq N_c} aff(Ab_{ij}(t)), \quad (6)$$

$Ab_i(t)$ 、 $Ab_{ij}(t+1)$ 、 $aff(Ab_i(t))$ 和 β 、 N_c 的含义同式(3). $Ab_g(t)$ 是当前拥有全局最大亲和力的抗体, r_1 、 r_2 和 r_3 是(0,1)间的随机数, c_1 和 c_2 是加权因子, 即亲和力学习因子和精英学习因子, 并有 $c_1+c_2=1$.

从式(4)可知, 新的候选抗体由3项构成: 第一项是父抗体, 第二项是亲和力学习, 第三项是精英学习. 同式(3)相比, 式(4)增加了第三项, 即特别的精英学习机制. 若 $Ab_i(t)$ 和 $Ab_g(t)$ 相差很大, 最后一项的值就会很大; 相反, 若 $Ab_i(t)$ 和 $Ab_g(t)$ 很接近, 则最后一项的值很小. 特别是当 $Ab_i(t)$ 等于 $Ab_g(t)$ 时, 则只有亲和力学习. 若要加快算法的搜索速度, 可在约束条件下增大 c_2 而减小 c_1 . 事实上, 不难发现, 当 $c_1=1$ 且 $c_2=0$ 时, 无论 $Ab_g(t)$ 是否等于 $Ab_i(t)$, 式(4)和式(5)都是相等的. 参数 β 的值可以是预设的, 也可根据不同的问题进行调整.

另一个精英保留策略用于清除退化的候选抗体. 当执行抗体抑制时, 所有的候选抗体按亲和力大小降序排列, 亲和力较高的抗体将被保留, 而亲和力较低的抗体将被删除. 亲和力学习和精英学习双重机制, 保证了EaiNet-EL优化算法在最优解的搜索质量和搜索速率上都优于传统aiNet算法.

4 仿真实验 (Simulation experiments)

4.1 平台选定和参数设定 (Benchmark selection and parameter setting)

为系统评估EaiNet-EL算法, 选择了两个经典函数作为实验对象, 即多峰值函数和Shaffer函数^[2]. 多峰值函数有很多局部峰值和一个全局最大值(约为4.253888); 而Shaffer函数是一个由许多同心峰脊包围的全局单峰值函数, 其最大值等于1. 其函数表达式分别如式(7)和式(8)所示.

多峰值函数:

$$f(x, y) = 1 + x \sin 4\pi x + y \sin \pi(4y + 1) \quad (7)$$

s.t. $-1 \leq x, y \leq 2$

Shaffer函数:

$$f(x, y) = 0.5 + \frac{(\sin \sqrt{x^2 + y^2})^2 - 0.5}{1 + 0.001(x^2 + y^2)} \quad (8)$$

s.t. $-10 \leq x, y \leq 10$

为比较研究EaiNet-EL和aiNet算法, 首先设置共同参数: $\beta=100$, 最大迭代次数 $maxEpoch=2000$, $N_c=4$. 此外, 设aiNet算法的初始化抗体数 $initN=20$, 抑制阈值 $t_s=0.1$; 而设EaiNet-EL算法 $initN=50$, $t_s=0.5$. 为探究EaiNet-EL中 c_1 和 c_2 的最佳取值组合, 在不同的因子取值组合下各重复执行仿真实验100次. 为对比研究EaiNet-EL和aiNet的优化性能, 各重复执行仿真实验1000次.

(1) 多模态函数(Multiple modal function, MMF)

使用最大搜索值($MaxFunc$)和最终迭代次数($FinalEpoch$)作为评价指标, 表1列出了EaiNet-EL算法在不同加权因子下求解MMF函数的数学统计(期望和标准差)结果, 其中针对每组因子都运行算法100次. 从表1可知, 当 c_1 在[0-0.6]内时, 由EaiNet-EL找到MMF的 $MaxFunc$ 的概率很高, 即最优解的标准差为0, 这表明EaiNet-EL算法每次都能成功地找到最优值. 而当 c_1 在[0.7-0.9]内时, $MaxFunc$ 的期望值降低到4.23; 而标准差接近0.01. 当 $c_1=1$ 时, 没有考虑精英学习, $MaxFunc$ 的期望值有轻微提高, 即4.249, 而标准差是0.05.

表1 用EaiNet-EL优化MMF时的数学统计结果

Table 1 Statistical results when the EaiNet-EL algorithm is applied to optimize MMF function

| c_1 | c_1 | $Max-Func$ | $Final-Epoch$ |
|-------|-------|---------------------|-----------------|
| 0 | 1 | 4.253888 ± 0 | 95.59 ± 79.48 |
| 0.1 | 0.9 | 4.253888 ± 0 | 57.36 ± 25.94 |
| 0.2 | 0.8 | 4.253888 ± 0 | 63.85 ± 44.40 |
| 0.3 | 0.7 | 4.253888 ± 0 | 83.71 ± 70.71 |
| 0.4 | 0.6 | 4.253888 ± 0 | 81.35 ± 6.20 |
| 0.5 | 0.5 | 4.253888 ± 0 | 92.55 ± 74.85 |
| 0.6 | 0.4 | 4.253888 ± 0 | 121.63 ± 110.93 |
| 0.7 | 0.3 | 4.234637 ± 0.081383 | 129.15 ± 91.45 |
| 0.8 | 0.2 | 4.224528 ± 0.104846 | 130.12 ± 96.54 |
| 0.9 | 0.1 | 4.230276 ± 0.093690 | 175.59 ± 120.58 |
| 1 | 0 | 4.248837 ± 0.049912 | 624.63 ± 231.20 |

学习因子的变化, 对 $FinalEpoch$ 评价指标的影响也有类似趋势. 当使用精英学习机制时, 即 c_1 在[0-0.9]内, 相应地, c_2 在[1-0.1]内时, $FinalEpoch$ 的期望值在57到176之间波动, 标准差小于120. 若不使用精英学习机制, 则最终迭代次数的期望值接近624.63, 标准差超过231.

从表1的数据和分析不难发现, 当 c_1 在[0-0.6]内, 相应地, c_2 在[1-0.4]内时, EaiNet-EL算法能得到较好的 $MaxFunc$ 和 $FinalEpoch$. 换言之, 当 c_1 和 c_2 在适当的范围内取值时, EaiNet-EL算法能以较快的收敛速度搜索到高质量的最优解.

更有说服力的比较结果将在EaiNet-EL算法和aiNet算法的1000次实验中得出. 基于表1的研究结果, 取 $c_1=0.5$ 和 $c_2=0.5$. 为了统计分析, 为优化所得的 $MaxFunc$ 选择四个评价指标: $MaxOfMaxFunc$ ($MaxFunc$ 的最大值)、 $AverOfMaxFunc$ ($MaxFunc$ 的平均值)、 $MinOfMaxFunc$ ($MaxFunc$ 的最小值)和 $StdOfMaxFunc$ ($MaxFunc$ 的标准差). 类似地, 为 $Final-Epoch$ 选择四个评

价指标: $MaxOfFinalEpoch$ ($FinalEpoch$ 的最大值)、 $AverOfFinalEpoch$ ($FinalEpoch$ 的平均值)、 $MinOfFinalEpoch$ ($FinalEpoch$ 的最小值)和 $StdOfFinalEpoch$ ($FinalEpoch$ 的标准差).

表2 优化求解MMF函数1000次的统计实验结果

Table 2 Statistical Results when the MMF function is optimized for 1000 duplications

| 指标 | 算法 | |
|--------------------|------------|------------|
| | aiNet | EaiNet-EL |
| $MaxOfMaxFunc$ | 4.253888 | 4.253888 |
| $AverOfMaxFunc$ | 4.249647 | 4.253369 |
| $MinOfMaxFunc$ | 3.634104 | 3.754746 |
| $StdOfMaxFunc$ | 0.046716 | 0.015797 |
| $MaxOfFinalEpoch$ | 595.000000 | 878.000000 |
| $AverOfFinalEpoch$ | 205.600000 | 97.330000 |
| $MinOfFinalEpoch$ | 21.000000 | 14.000000 |
| $StdOfFinalEpoch$ | 91.530000 | 82.820000 |

表2给出了分别运行EaiNet-EL优化算法和传统aiNet优化算法1000次的统计实验结果.一方面,两种优化算法都能找到相同最大值的最优解,但EaiNet-EL优化算法的统计结果有更大的 $AverOfMaxFunc$ 和 $MinOfMaxFunc$,且 $StdOfMaxFunc$ 更小.这表明EaiNet-EL算法有更好的鲁棒性和更强的最优解搜索能力.另一方面,与传统aiNet优化算法相比,尽管 $MaxOfFinalEpoch$ 值较大,但EaiNet-EL优化算法具有更小的 $AverOfFinalEpoch$, $MinOfFinalEpoch$ 和 $StdOfFinalEpoch$.

(2) Shaffer函数(Shaffer's function, SSF)

使用SSF函数作为EaiNet-EL算法和aiNet算法的优化对象.首先,重复运行EaiNet-EL算法以发现最佳的组合因子.在不同的组合因子下,运行EaiNet-EL算法100次.表3给出了一系列典型组合因子下的统计实验结果,所用评价指标同表1.从表3可知,当 c_1 在[0.5-0.9]内、 c_2 在[0.5-0.1]内时,对SSF优化的最大值大于0.998.若 c_1 或者 c_2 在上述范围外取值,则对SSF优化的最大搜索值会有轻微的降低,即0.996.不管亲和力学学习因子 c_1 和精英学习因子 c_2 怎么变化,最大搜索值的标准差都可以维持在较低水平,即0.01-0.07.

不难发现,当 c_1 小于1,即引入精英学习机制时, $FinalEpoch$ 的期望值大约为250.若 c_1 等于1,即不考虑精英学习机制,那么 $FinalEpoch$ 将急剧上升到667.可见,从PSO引入的精英学习机制可以加速EaiNet-EL算法的收敛,并且其计算代数远小于

传统aiNet算法.因此,EaiNet-EL算法中亲和力学习因子 c_1 的最佳取值范围应该是0.5-0.9,这可以确保在较少的计算量下找到较大的最优值.

表3 用EaiNet-EL优化SSF时的数学统计结果

Table 3 Statistical results when the EaiNet-EL algorithm is applied to optimize the SSF function)

| c_1 | c_2 | $MaxFunc$ | $FinalEpoch$ |
|-------|-------|--------------------|-----------------|
| 0 | 1 | 0.997022 ± 0.00445 | 230.31 ± 224.49 |
| 0.1 | 0.9 | 0.996869 ± 0.00451 | 200.20 ± 183.80 |
| 0.2 | 0.8 | 0.997634 ± 0.00408 | 200.05 ± 168.34 |
| 0.3 | 0.7 | 0.996773 ± 0.00458 | 214.06 ± 201.64 |
| 0.4 | 0.6 | 0.997822 ± 0.00396 | 216.05 ± 181.56 |
| 0.5 | 0.5 | 0.998430 ± 0.00340 | 211.29 ± 186.90 |
| 0.6 | 0.4 | 0.998580 ± 0.00322 | 211.19 ± 159.39 |
| 0.7 | 0.3 | 0.998390 ± 0.00323 | 222.53 ± 168.20 |
| 0.8 | 0.2 | 0.999405 ± 0.00206 | 266.30 ± 167.48 |
| 0.9 | 0.1 | 0.999803 ± 0.00103 | 250.17 ± 116.92 |
| 1 | 0 | 0.997991 ± 0.00783 | 667.78 ± 241.75 |

表4 优化求解SSF函数1000次时的统计实验结果

Table 4 Statistical Results when the SSF function is optimized for 1000 duplications)

| 指标 | 算法 | |
|--------------------|-------------|------------|
| | aiNet | EaiNet-EL |
| $MaxOfMaxFunc$ | 1.000000 | 1.000000 |
| $AverOfMaxFunc$ | 0.997337 | 0.998022 |
| $MinOfMaxFunc$ | 0.962776 | 0.990284 |
| $StdOfMaxFunc$ | 0.006253 | 0.003798 |
| $MaxOfFinalEpoch$ | 1000.000000 | 985.000000 |
| $AverOfFinalEpoch$ | 520.990000 | 204.960000 |
| $MinOfFinalEpoch$ | 8.000000 | 5.000000 |
| $StdOfFinalEpoch$ | 310.200000 | 178.040000 |

接下来,比较EaiNet-EL算法和aiNet算法在SSF函数优化上的性能.根据前面的研究结果,EaiNet-EL优化算法简单地选择 $c_1=0.5$ 和 $c_2=0.5$.表4给出了重复运行EaiNet-EL优化算法和传统aiNet优化算法各1000次的统计实验结果,各项评价指标同表2有着相同的趋势.一方面,相比传统aiNet优化算法,EaiNet-EL优化算法不仅具有相同的 $MaxOfMaxFunc$,而且有更小的 $AverOfMaxFunc$, $MinOfMaxFunc$ 和更小的 $StdOfMaxFunc$.另一方面,EaiNet-EL优化算法在 $MaxOfFinalEpoch$, $AverOfFinalEpoch$, $MinOfFinalEpoch$ 和 $StdOfFinalEpoch$ 上都较传统aiNet优化

算法具有更小的值。

(3) 结果讨论(Results discussion)

虽然传统aiNet优化算法的优点在于可以搜索出局部最优解,但是它不能满足人们对搜索效率和求解质量的要求.相比之下,本文提出的EaiNet-EL优化算法,吸收了PSO的精英学习思想,从而具有更快的收敛速度以及更佳的最优解. EaiNet-EL算法对于全局精英解同样保持了自身进化机制.因此, EaiNet-EL优化算法在最优解质量和收敛速度上比aiNet优化算法表现出更好的性能.

人工免疫系统的性能取决于抗体群信息的挖掘和利用.本文研究了式(4)中的加权因子,并针对两个经典函数的优化找到了加权因子的最优取值范围.不同的目标问题可能具有不同的取值范围,因此对于具体的问题应该具体分析.

4.2 在工业PID控制器中的应用 (An application in industrial PID controller)

PID控制器广泛应用于机器人和过程控制,工业界超过95%的闭环控制都采用PID控制. PID控制器有很多整定方法,如手动调试、ZN法、分析法、优化法、自动整定法等^[7,14,15].为了优化PID控制系统的性能,应该调整系统的PID增益使得某一性能指标达到最大值或最小值.性能指标的计算基于时间间隔 T ,通常取 $0 \leq T \leq T_s$,其中 T_s 是系统的稳定时间.本文选择以下四个性能指标来调整PID增益:误差绝对值与时间的积分(ITAE)、误差绝对值积分(IAE)、误差平方积分(ISE)和误差平方均值(MSE),其数学表达式是:

$$I_{ITAE} = \int_0^T t|e(t)|dt. \quad (9)$$

$$I_{IAE} = \int_0^T |e(t)|dt. \quad (10)$$

$$I_{ISE} = \int_0^T e^2(t)dt. \quad (11)$$

$$I_{MSE} = \frac{1}{n} \sum_{k=1}^n e^2\left(\frac{KT}{n}\right). \quad (12)$$

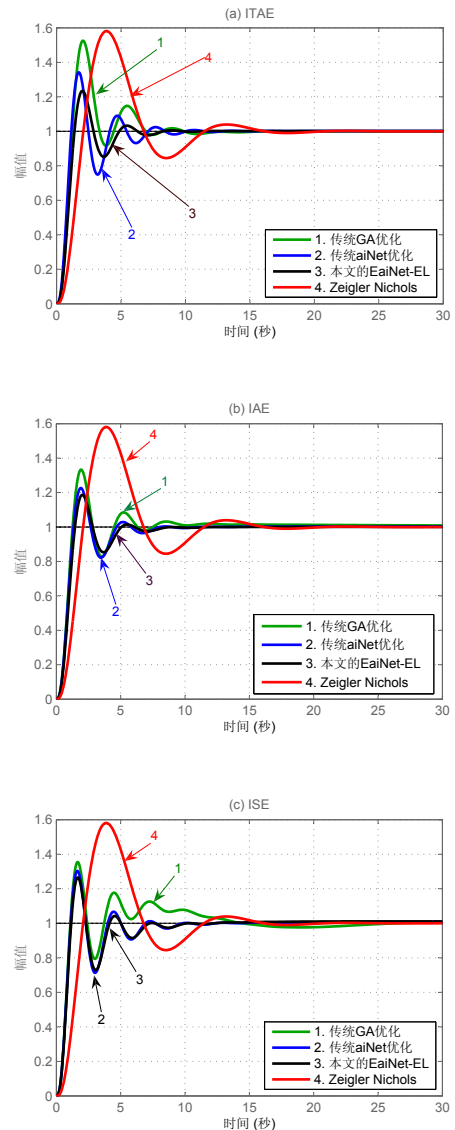
假设系统的传递函数是

$$G(s) = \frac{1}{s(s^3 + 6s^2 + 11s + 6)}. \quad (13)$$

而PID控制器的传递函数形式是

$$D_c(s) = K_p + \frac{K_I}{s} + K_D s. \quad (14)$$

这里,选用几个经典的PID参数整定方法与EaiNet-EL优化算法作比较,分别是ZN法(Ziegler-Nichols),遗传算法和传统aiNet算法.经四种方法整定后的控制系统阶跃响应曲线如图2所示,其中图2(a)-(d),分别对应于ITAE、IAE、ISE和MSE四个指标的优化.为便于观察, PID控制响应曲线以不同颜色绘出,红色代表ZN法,绿色代表遗传算法(GA),蓝色代表aiNet算法,黑色代表EaiNet-EL算法.同其它三种方法相比,使用EaiNet-EL算法得到的系统阶跃曲线,无论在何种评价指标下,始终具有最小的超调量和最短的稳定时间.这表明, EaiNet-EL优化算法更能有力搜索到最佳的向量组合(k_P , k_I 和 k_D).因此,经EaiNet-EL算法整定后的过程控制系统(如式(13)所示),将有更好的控制性能.



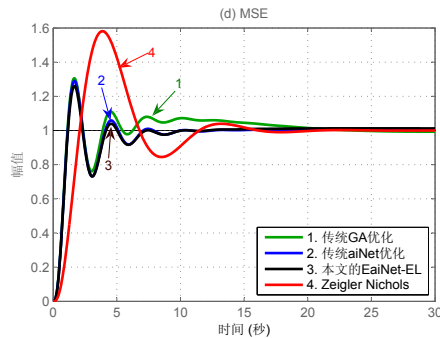


图2 四种方法整定后的PID控制系统阶跃响应曲线对比((a)ITAE, (b)IAE, (c)ISE和(d)MSE)

Fig.2 Step response curves of PID control system tuned by four methods ((a)ITAE, (b)IAE, (c)ISE and (d)MSE)

5 结论和展望 (Conclusions and future work)

受PSO的启发,本文提出了一种带有精英学习能力的增强型人工免疫网络(EaiNet-EL).精英学习机制的引入旨在提高人工免疫系统的收敛速度以及最优解质量.在用于函数优化的传统aiNet优化算法的基础上,重新设计免疫操作,增加了精英学习因子.同时,采用精英保持策略用以避免抗体的退化.仿真实验结果表明,EaiNet-EL算法优于aiNet算法.此外,通过PID工业应用实验的研究,本文也验证了EaiNet-EL算法的工程应用价值.

EaiNet-EL优化算法在最优解质量和收敛速度上都被证明是有效的优化方法;然而如何避免繁重的计算量,已成为免疫系统的重要研究方向.因此,今后将研究加快计算速度的新方法以满足实时控制系统的要求.

参考文献 (References):

- [1] DE CASTRO L N, TIMMIS J. *Artificial Immune Systems: A New Computational Intelligence Approach*[M]. London: Springer-Verlag, 2002.
- [2] DE CASTRO L N, TIMMIS J. An artificial immune network for multimodal function optimization [C] // *Proc of IEEE Congress on Evolutionary Computation*, New York: IEEE Press, 2002, 1: 699–674.
- [3] TIMMIS J, KNIGHT T, DE CASTRO L N, HART E. An overview of artificial immune systems [C] // *Computation in Cells and Tissues: Perspectives and Tools Thought*. London: Springer-Verlag, 2004, 51–86.
- [4] 李中华, 谭洪舟, 张雨浓, 毛宗源. 基于免疫算法的午饭时期层间高峰交通电梯群控制的动态优化[J]. *控制理论与应用*, 2007, 24(2): 177–182.
(LI Zhonghua, TAN Hong-Zhou, ZHANG Yunong, MAO Zongyuan. Dynamic optimization of elevator group control based on artificial immune algorithm for inter-floor peak traffic during lunch-time[J]. *Control Theory and Applications*, 2007, 24(2): 177–182.)
- [5] LI Z H, TAN H.-Z. A combinational clustering method based on artificial immune system and support vector machine[C] // *Lecture Notes in Computer Science*, Berlin: Springer-Verlag, 2006, 4253: 153–162.
- [6] SUN W D, TAMURA H, Tang Z, ISHII M. An artificial immune network with diversity and its applications [C] // *Proc of 2003 IEEE EMBS Asian-Pacific Conf Biomedical Engineering* New York: IEEE Press, 2003, 326–327.
- [7] KIM D H. Tuning of a PID controller using an artificial immune network model and local fuzzy set[C] // *Proc of IEEE Int Symposium Industrial Electronics*. New York: IEEE Press, 2001, 1656–1661.
- [8] WIDYANTO M R, KUSUMOPUTRO B, NOBUHARA H, KAWAMOTO K, HIROTA K. A fuzzy-similarity-based self-organized network inspired by immune algorithm for three-mixture-fragrance recognition[J]. *Trans. on Industrial Electronics*, New York: IEEE Press, 2006, 53(1): 313–321.
- [9] 李春华, 朱燕飞, 毛宗源. 一种新型的自适应人工免疫算法[J]. *计算机工程与应用*, 2004, 40(22): 84–87.
(LI Chunhua, ZHU Yanfei, MAO Zongyuan. A novel adaptive artificial immune algorithm[J]. *Computer Engineering and Applications*, 2004, 40(22): 84–87.)
- [10] TIAN X, YANG H D, DENG F Q. A novel artificial immune network [C] // *Proc of the Fifth Int Conf Machine Learning and Cybernetics*, New York: IEEE Press, 2006, 2159–2165.
- [11] 洪露, 穆志纯. 基于“Stretching”技术的免疫遗传算法的研究[C]. 第25届中国控制会议论文集, 北京: 北京航空航天大学出版社, 2006, 1423–1427.
(HONG Lu, MU Zhichun. Study of immune genetic algorithm based on “stretching” technique [C] // *Proc of the 25th Chinese Control Conference*, Beijing: Beijing University of Aeronautics and Astronautics Press, 2006, 1423–1427.)
- [12] 曾建潮, 介婧, 崔志华. 微粒群算法 [M]. 北京: 科学出版社, 2004.
(ZENG Jianchao, JIE Jing, CUI Zhihua. *Particle Swarm Optimization Algorithm*[M]. Beijing: Science Press, 2004.)
- [13] BERGH F, ENGELBRECHT A P. A cooperative approach to particle swarm optimization [J]. *IEEE Trans on Evolutionary Computation*, New York: IEEE Press, 2004, 8(3): 225–239.
- [14] GRIFFIN I. *On-line PID Controller Tuning Using Genetic Algorithms*[D]. Dublin: Dublin City University, 2003.
- [15] JANTZEN J. *Tuning of Fuzzy PID Controllers*[M]. Copenhagen: Technical University of Denmark, 1998.

作者简介:

李中华 (1977—), 男, 博士, 中山大学信息科学与技术学院讲师, 硕士生导师, 主要从事智能计算与优化控制、嵌入式系统与IC设计应用等的研究, E-mail: lizhongh@mail.sysu.edu.cn.

张雨浓 (1973—), 男, 博士, 中山大学信息科学与技术学院教授, 博士生导师, 主要从事递归神经网络、冗余机器人和高斯过程的计算及优化研究, E-mail: zhyong@mail.sysu.edu.cn.

谭洪舟 (1965—), 男, 博士, 中山大学信息科学与技术学院教授, 博士生导师, 主要从事智能系统与盲信号处理、集成电路设计的研究, E-mail: lizhongh@mail.sysu.edu.cn.

陈卓怡 (1986—), 女, 工学学士, 2008年于中山大学信息科学与技术学院毕业后, 前往美国留学, 主要从事演化计算与信号处理方面的研究, E-mail: chenzyocat@yahoo.com.cn.