

# 免疫克隆算法调节参数的非线性控制器设计

黄忠报, 李士勇

(哈尔滨工业大学 控制科学与工程系, 黑龙江 哈尔滨 150001)

**摘要:**以模糊神经网络(FNN)为基础,结合误差线性反馈构造了一种新型的非线性控制器.非线性控制器的设计难点在于参数的确定问题,用传统的算法对控制器参数寻优时容易陷入局部收敛,难于取得可靠的参数,因此提出一种改进的免疫克隆选择算法,用于确定非线性控制器的最优参数.倒立摆的仿真实验表明改进的免疫克隆算法在控制器参数寻优中取得良好的效果,所设计的控制器具有很强的非线性适应能力.

**关键词:**改进的免疫克隆选择算法;非线性控制器;参数寻优

**中图分类号:** TP273 **文献标识码:** A **文章编号:** 1673-4785 (2008) 05-0408-08

## A nonlinear controller design using an immune clonal selection algorithm

HUANG Zhong-bao, LI Shi-yong

(Department of Control Science and Engineering, Harbin Institute of Technology, Harbin 150001, China)

**Abstract:** A nonlinear controller based on a fuzzy neural network (FNN) and linear error feedback was constructed. But the difficulty in nonlinear controller design lies in identification of the parameters being controlled. Optimization of the parameters may lead to a local convergence if traditional methods are used, resulting in unreliable operation. We therefore developed a modified immune clonal selection algorithm (m-ICSA) to optimize parameters of the nonlinear controller. A simulation with an inverted pendulum demonstrated that the m-ICSA effectively optimizes controller parameters and the design has strong nonlinear adaptive ability.

**Keywords:** m-ICSA; nonlinear controller; parameter optimization

模糊神经网络(FNN)以其很强的非线性适应能力,近年来在控制器设计中得到广泛的应用,是模糊理论同神经网络相结合的产物,集学习、联想、识别、自适应及模糊信息处理于一体,能解决传统PD控制器对于迟滞性非线性对象的控制显得无能为力的问题.但是以FNN为基础的控制器的设计最关键的

问题是参数的确定.随着控制状态变量的增加,所用到的模糊规则和神经元也成倍地增多,这给控制器的参数寻优造成极大的困难.传统的误差反向训练方法<sup>[1]</sup>容易陷入局部收敛,而且还依赖于初始值,有时会出现训练退化的现象,使得控制对象的状态

变量不断远离所要求目标点的情况,其误差反馈到输入端时会超出控制器所能承受的范围,引起运算出现“爆炸”的情况.而采用遗传算法等传统的智能算法容易引起过早收敛的问题,不能很好地确定控制器的参数.因此本文从两方面设计新型的非线性控制器:一方面,把控制对象的误差状态变量 $e$ 作为模糊神经网络的输入端,把反映控制对象误差变化的状态变量 $e$ 通过线性反馈作为补偿与模糊神经网络的输出量相加,最后作为控制器的输出;另一方面,提出一种改进的免疫克隆算法,用于优化所改进的非线性控制器.

基于生物免疫系统的自学习、自适应<sup>[2]</sup>等智能特性,近年来相继出现了许多新颖的免疫算法,如启发式自适应免疫克隆算法<sup>[3]</sup>.生物免疫系统蕴含耐

收稿日期: 2008-03-21.

基金项目: 国家自然科学基金资助项目(60773065).

通信作者: 黄忠报. E-mail: hzhbba@163.com.

受性、免疫记忆、分布式并行处理、自组织、自学习、自适应和鲁棒性等强大的信息处理能力,可为工程领域提供各种富有成效的智能计算和方法。免疫克隆选择算法来源于传统的生物免疫克隆原理<sup>[4]</sup>,由 De Castro<sup>[5-6]</sup>在此基础上于 2000 年将克隆选择原理引入到免疫算法中,用于求函数极值取得很好的效果,此外,还将其应用到数据挖掘<sup>[7]</sup>中。文献[8]利用 Parzen 窗估计法来计算抗体的熵并作为选择抗体的依据,进而提出了一种新型的免疫进化算法。但是,这些算法在计算抗体的熵作为抗体选择的评价值时都没有结合抗体的适应度。本文把抗体熵与适应度加权作为抗体选择的评价值,同时采取高斯变异策略使抗体成熟,提出了一种改进的免疫克隆选择算法(modified immune clonal selection algorithm, m-ICSA),并在此基础上对设计的新型非线性控制器参数寻优。

## 1 改进的免疫克隆选择算法

基于抗体克隆选择机理,采用克隆选择算子的算法统称为免疫克隆选择计算<sup>[9]</sup>。为免疫克隆选择算法建立一个统一的描述,首先把抗原、抗体分别对应要解决的问题和候选解,将抗体亲合力的计算作为寻找最优解的依据;然后模拟淋巴细胞再生过程,对抗体进行克隆操作,扩增出新的个体,同时模拟抗体的成熟过程,对候选解进行高频变异操作,在其局部搜索空间中选择亲合力最大的抗体;最后根据免疫系统的正负反馈调节机制,如果抗体的浓度超过一定的阈值,就进行抑制,保持抗体的浓度平衡。可以把克隆选择算法分为以下 4 个步骤:

1) 克隆操作。根据文献[9]的方法,对每个抗体施加克隆算子,使其扩增裂变成若干子抗体,扩增的数量取决于抗体的适应度(亲合力)和当前抗体群的总数,如下所述:

记向量  $X = (x_1, x_2, \dots, x_m)$  的优化问题为  $P$ , 即  $\max f(x), x \in X$   $f(x)$  对应的抗体适应度设为  $AI(x)$  (在一些条件下需要把  $f(x)$  转化为相应的亲合度,以便对抗体评价进行估算,例如出现  $f(x) < 0$  时,一般地,通过  $AI(x) = \exp(\arctan(f(x)))$ , 将其映射到区间  $[\exp(-\frac{1}{2}), \exp(\frac{1}{2})]$ 。由此当前初始群体  $A_i$  的个体  $X_i$  通过施加克隆算子  $q_i$  后分别扩增出  $q_i$

个子个体;当前群体(其样本总数为  $m$ )即  $A_i = \{X_1, X_2, \dots, X_m\}$ , 克隆算子<sup>[9]</sup>为

$$q_i = g(X_i, m) = \text{Int}(m \cdot \frac{AI(X_i)}{\sum_{j=1}^m AI(X_j)}). \quad (1)$$

式中:  $\text{Int}(\cdot)$  表示上取整函数,由此当前抗体扩增为  $\bar{A}_i = \{\bar{X}_{i1}, \bar{X}_{i2}, \dots, \bar{X}_{iq_i}, \bar{X}_2, \dots, \bar{X}_{mq_m}\}$ , 则群体  $A_i$  的数量扩增为  $nt = \sum_{i=1}^m q_i$ , 这样可以保证每个抗体在克隆阶段不被除掉,有利于保持个体的多样性。

2) 高频变异成熟操作。为了提高抗体局部搜索能力,文献[10]在 De Castro 提出的免疫克隆选择算法基础上,对抗体的每个基因分量施加了变异算子  $k$ ,  $k = \exp(-f^*) \cdot (1 + \text{Gauss}(0, 1)) / 10$ ,  $f^*$  为抗体的适应度,  $\text{Gauss}(0, 1)$  为随机高斯算子。其采取的操作方法是:对于每个抗体的分量,首先在其正负方向分别对称地施加该变异算子,扩展出 2 个相应的子抗体,这样每个  $n$  维抗体扩出  $2n$  个子个体,然后选出该子群中的最优个体,用于估算其确定的超立方体的最好顶点。该方法在电磁场参数优化问题中取得良好的效果。

由于在实际应用中抗体的适应度  $f^*$  可能会很大,使得变异算子趋向于 0,影响进一步的有效搜索。因此本文引入反余切函数,使施加的变异算子为

$$kl = \exp(-\arctan(AI)) \cdot (1 + \text{Gauss}(0, 1)) / 2 \quad (2)$$

式中:  $AI$  为抗体的亲合力,对应于  $f^*$ 。为了进一步对克隆后的群体  $\bar{A}_i$  进行变异成熟操作,按如下方法进行操作:对于原抗体群  $A_i$  的个体  $X_i$ ,如果按步骤 1) 所求得的相关克隆算子  $q_i = 1$ ,按照文献[10]的方法(如上文说明)对其进行高频变异成熟操作;如果克隆算子  $q_i > 2$ ,先从  $X_i$  的克隆体中选一抗体  $\bar{X}_{ij} (1 \leq j \leq q_i)$  按照文献[10]的方法进行高频变异操作,余下的  $q_i - 1$  个克隆子抗体分别对其所有的基因分量都施加式(2)所示的变异算子。

需要说明的是,  $\bar{X}_{ij} (1 \leq j \leq q_i)$  施加变异算子  $kl$  以后,得到的变异个体  $\bar{X}_{ij}$  可能会超出搜索空间的范围。De Castro 提出的免疫克隆选择算法中在这问题上直接用原来的抗体取代  $\bar{X}_{ij}$ 。为了进一步提高局搜索能力,当出现超出搜索空间的变异个体时,本文对变异算子  $kl$  作如下的修正:

记抗体  $X = (x_1, x_2, \dots, x_m)$  的基因分量  $x_i$  的搜索范围为  $[a_i, b_i]$ , 则修正的变异算子  $kl$  在正方向上取为

$$kl = (b_i - x_i) \exp(-\arctan(AI)) \text{rand} \quad (3)$$

负方向的修正变异算子  $kl$  取为

$$kl = (a_i - x_i) \exp(-\arctan(AI)) \text{rand} \quad (4)$$

式中:  $\text{rand}$  为  $[0, 1]$  的随机变量. 由此抗体  $X_i$  得到相应的  $2n + q_i$  个变异子个体. 最后由  $X_i$  及其  $2n + q_i$  个子抗体组成的子群体选择亲合力较大的  $q_i$  个抗体进入下一代, 由此得到  $X_i$  的成熟抗体群, 记为  $B_r$ .

3) 更新记忆抗体. 从成熟后的群体  $B_r$  取出亲合力较大的  $N_c$  (一般取  $10 \sim 20$ , 并且满足  $N_c < |B_r|$ ,  $|B_r|$  表示  $B_r$  的个体总数) 个抗体, 组成为群体  $B_c$ , 用于更新记忆抗体  $M$ . 操作方法是: 首先把  $B_c$  插入到记忆抗体  $M$  中, 最后由它们组成的群体选择  $|M|$  个亲合力较大的群体保留下来成为新的记忆抗体群  $M$ , 其余的抗体删除掉.

4) 浓度调节操作. 由免疫学理论<sup>[4]</sup>, 抗体受到抗原刺激反应后, 在初始阶段通过克隆裂变, 不断成熟, 成为记忆抗体保留下来; 当抗体的数量扩增到一定阈值后应该进行调节, 一些抗体的数量受到抑制. 一般地, 在受抗原刺激的开始阶段, 抗体呈指数增长; 相应的抑制机制很微弱, 经过若干周期后, 抑制力会逐渐增强, 使抗体的浓度达到平衡. 由于难于用一个具体的数学表达式来描述这一动态过程 (而且也没必要这样做), 本文认为抗体在指数增长  $1 \sim 2$  个周期时, 也就是当抗体的数量  $N_t > 4N_0$  ( $N_0$  为初始抗体的数量) 时免疫系统开始对抗体进行抑制, 并且骨髓又产生新的  $[N_t/5]$  ( $[ \cdot ]$  表示上取整符号) 个新抗体.

抑制抗体的过程实质上是克隆选择过程: 保留一些个体进入下一代, 清除一些评价价值过低的抗体. 确定好抗体的评价价值才能对抗体进行有效地选择, 便以搜索潜在的更优个体. 传统的克隆选择算法只是按照抗体亲合力的大小作为抗体选择的标准, 这不利于保持抗体的多样性, 进而影响到进一步搜索潜在最优解的可能性. 为此应该对抗体的评价价值作新的定义. 根据免疫学正负反馈的浓度调节机制, 适应度低而浓度又高的抗体繁殖应该受到抑制, 同时应该激励那些有助于杀灭抗原而浓度又比较低的抗体, 使抗体不断优化. 信息熵<sup>[11-13]</sup>是反映抗体多样

性的估算方法, 然而它是基于抗体基因型空间的, 不适合实数编码的算法. 文献[8]利用 Parzen 窗估计法来计算抗体的熵并以此作为选择抗体的依据. 这是估算实数编码空间的抗体分布的一种重要方法, 本文参考该方法对抗体的评价价值进行估算.

从空间几何的角度考虑, 当个体均匀分布于搜索空间时最有利于进行全局搜索. 当群体中的大部分抗体聚集在一个局部空间, 而少数的个体远离它们, 那么这些孤立的个体更能有利于搜索更优个体, 应当保留下来进入下一代. 根据 Parzen 窗估计法得出的概率密度函数特点, 孤立的个体相应的概率密度就比较小. 如果它的适应度较高就更应当被选择, 并在由其构成的局部空间生成更多的抗体便以进一步搜索更优抗体, 因此赋予它的评价价值就应当比较高; 相反, 概率密度比较大 (它的浓度大) 而适应度低的抗体, 就应当被抑制, 被新的抗体所取代, 使抗体朝着有利于搜索潜在更优抗体的方向进化. 因此抗体的选择评价价值应当是 Parzen 窗估计概率密度的减函数, 是适应度的增函数. 确定方法如下:

对于抗体群

$$U = \{u_i \mid i = 1, 2, \dots, |U|\}. \quad (5)$$

式中:  $u_i \in R^n$ ,  $|U|$  表示种群总数, 抗体的第  $j$  个基因分量  $u_{ij} \in [a_j, b_j]$ , 根据 Parzen 窗估计法, 抗体  $u$  的局部空间概率密度估计值为

$$\hat{p}(u) = \frac{1}{|U|} \sum_{i=1}^{|U|} \exp(-\frac{1}{2}(u - u_i)^T \Sigma^{-1}(u - u_i)). \quad (6)$$

式中: 核函数 采用多变量的高斯函数, 表示为

$$\exp(-\frac{1}{2}(u - u_i)^T \Sigma^{-1}(u - u_i)) = \frac{1}{(2\pi)^{\frac{n}{2}} |\Sigma|^{\frac{1}{2}}} \exp(-\frac{1}{2} u^T \Sigma^{-1} u). \quad (7)$$

式中:  $T$  为转置操作,  $\Sigma$  为协方差矩阵, 取为对角矩阵, 按照文献[8]的方法, 其对角元素表示为抗体相应的基因分量的方差即

$$\sigma_j^2 = \frac{u_{j\max} - u_{j\min}}{|U|}. \quad (8)$$

式中:  $u_{j\max}$  和  $u_{j\min}$  分别表示群体中的抗体在第  $j$  基因分量的最大值和最小值. 如果  $\sigma_j = 0$ , 取  $\sigma_j = 10^{-4}$ .

不同于文献[8]的抗体评价价值估算法, 本文作如下的评价价值估算:

$$I(u_i) = 1 - \hat{p}(u_i) + w * \arctan(AI(u_i)). \quad (9)$$

式中:  $w$  为抗体亲合力的影响权值, 一般取  $0.05 \sim$

Q 4 反余切函数的作用是把抗体的适应度都映射到区  $[0, \frac{1}{2}]$ , 避免它的值过大而使得评价中 Parzen 窗估计部分因值较小而被忽略掉. 该评价的作用是通过 Parzen 窗估计的部分评价值相差不大的情况下, 适应度较高的个体被保留下来, 使得所选择的抗体, 其在空间的分布更有利于搜索潜在的最优解. 对于被除掉的一些抗体, 由搜索空间随机产生的  $[|B_1|/5]$  个抗体来取代, 这是模拟骨髓产生抗体的简单过程. 所得到的程序设计框图如图 1 所示.

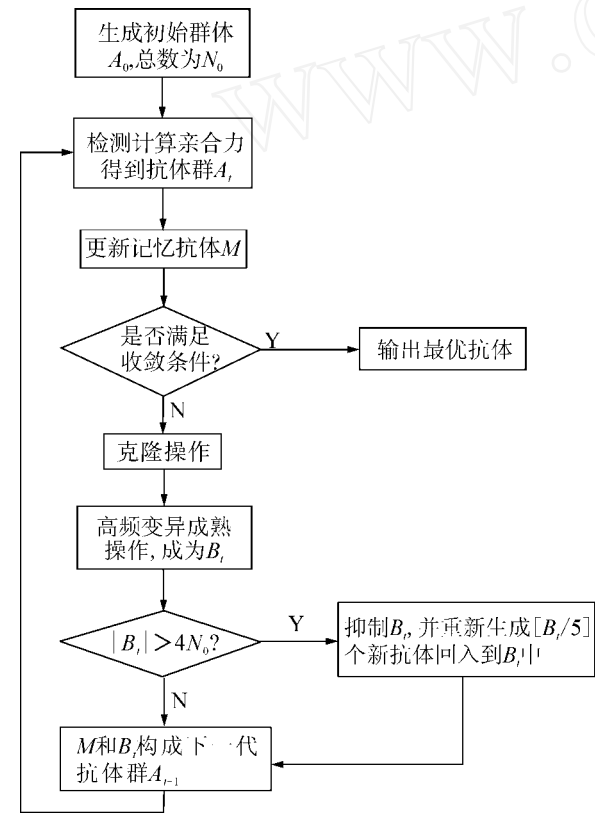


图 1 m-CSA 算法的结构图  
Fig 1 The block diagram of m-CSA

2 用免疫算法优化的非线性控制器

本文以模糊神经网络<sup>[14]</sup>为基础, 结合线性反馈设计非线性 FNN 控制器, 用改进的免疫算法优化控制器的参数. 文献 [15] 所设计的神经模糊控制器, 通过引入比例因子先把输入的状态变量都归一到区间  $[-1, 1]$ , 然后都输入到模糊神经网络控制器的输入端, 这导致控制器的参量过多难于调节参数. 本文所设计的  $n$  端输入控制器如图 2 所示. 为了减少控制器参数, 首先将输入变量进行分类, 把作为重要

参考的  $k$  个误差状态变量  $\bar{x}_1 = (x_1, x_2, \dots, x_k)^T$  作为模糊神经网络的输入端, 另外的  $n - k$  个关于误差变化率的状态变量  $\bar{x}_2 = (x_{k+1}, x_{k+2}, \dots, x_n)^T$  直接通过线性反馈 ( $K_1, K_2, \dots, K_{n-k}$ ) 与模糊神经网络的输出量相加, 最后得到控制器的输出.




图 2 改进的非线性控制器  
Fig 2 The improved nonlinear controller

模糊神经网络实质上是带乘积推理的模糊系统. 对于状态变量  $x_i$  的  $n_i$  个模糊集合记为  $\bar{A}_{i1}, \dots, \bar{A}_{ij}, \dots, \bar{A}_{in_i}$ , 其高斯隶属函数记为

$$\mu_{ij}(x_i) = \exp\left\{-\frac{(x_i - \bar{x}_{ij})^2}{2\sigma_{ij}^2}\right\} \quad (10)$$

第  $l$  条规则对应的乘积高斯算子为

$$z^l = \prod_{i=1}^k \exp\left\{-\frac{(x_i - \bar{x}_{il})^2}{2\sigma_{il}^2}\right\} \quad (1 \leq l \leq m) \quad (11)$$

式中:  $(\bar{x}_{11}, \sigma_{11}, \bar{x}_{12}, \sigma_{12}, \dots, \bar{x}_{k1}, \sigma_{k1})$  实质上是状态变量  $(x_1, x_2, \dots, x_i, \dots, x_k)$  分别对应的高斯隶属函数参数  $(\bar{x}_{1m_1}, \sigma_{1m_1}, \bar{x}_{2m_2}, \sigma_{2m_2}, \dots, \bar{x}_{km_k}, \sigma_{km_k})$ , 满足  $1 \leq m_1 \leq n_1, \dots, 1 \leq m_k \leq n_k$ , 并由  $m_1, m_2, \dots, m_k$  分别在其取值范围内随机取任一整数值得到的一组值, 则共有的模糊规则数为

$$m = C_{n_1}^1 \times C_{n_2}^1 \times \dots \times C_{n_k}^1 = \prod_{i=1}^k n_i \quad (12)$$

由此可以方便地用式 (11) 来表示高斯算子. 模糊神经网络的输出为<sup>[14]</sup>

$$f = \frac{\sum_{l=1}^m \left[ \prod_{i=1}^k \exp\left\{-\frac{(x_i - \bar{x}_{il})^2}{2\sigma_{il}^2}\right\} \right]}{\sum_{l=1}^m \left[ \prod_{i=1}^k \exp\left\{-\frac{(x_i - \bar{x}_{il})^2}{2\sigma_{il}^2}\right\} \right]} \quad (13)$$

加入线性反馈后, 得到具有  $n$  个输入端的控制器:

$$u = \sum_{l=1}^m \bar{y}^l z^l / \sum_{l=1}^m z^l + K_1 x_{k+1} + \dots + K_{n-k} x_n \quad (14)$$

设控制器作为模糊神经网络输入端的状态变量为  $\bar{x} = (x_1, x_2, \dots, x_k)^T$ , 它的每个变量  $x_i$  对应的模糊集合数  $n_i$  是一定的. 用改进的免疫算法优化这些参数时, 抗原对应要优化的问题,  $B$  细胞产生的抗体及其亲合力分别对应控制器参数的解空间及评价参数的指标函数. 根据第 1 节所给出的改进算法, 参数寻优的步骤如下:

1) 生成抗体. 由于抗体基因较多, 采用二进制编码, 转换计算开销大, 所以采用实数编码. 首先随机产生  $N_0$  个抗体, 组成初始群体  $A_0$ . 对应于式 (10) ~ (14) 所要确定的参数, 抗体可以表示为序列  $(\bar{x}_{11}, \dots, \bar{x}_{1n_1}, \dots, \bar{x}_{il}, \dots, \bar{x}_{kn_k}, \bar{y}, \dots, \bar{y}^m, K_1, K_2, \dots, K_{n-k})$ , 编码长度为

$$nl = 2 \sum_{i=1}^k n_i + \sum_{i=1}^k n_i + n - k \quad (15)$$

2) 检测及计算抗体亲合力. 为了使控制对象的状态尽快回到平衡位置, 同时希望控制器的输出尽可能小, 本文采取如下所示的二次型性能指标:

$$J = \int_0^{\infty} (x^T(t) Q x(t) + u^T R u(t)) dt \quad (16)$$

优化的结果就是要使  $J \rightarrow \min$ . 由于有些抗体使得系统的状态越来越偏离平衡位置, 使得  $\sum_{i=1}^m z_i$  趋向无穷大, 由式 (14) 计算得到的  $u$  为无穷大, 这给计算评价造成很大的困难, 因此本文先对群体检测, 如果在计算抗体指标值过程中出现  $\sum_{i=1}^m z_i < \epsilon$  ( $\epsilon$  为很小的一个正常数, 一般取  $10^{-15}$ ), 清除掉该抗体. 这是模拟抗体自然死亡的简单过程. 对于满足检测条件的抗体计算其亲合力:

$$AI = \frac{1}{a + J} \quad (17)$$

式中:  $a$  为一个很小的正数, 保证分母不为零. 由此, 得到符合检测要求的群体  $A_t$ , 记其种群数为  $N_t$ .

3) 更新记忆抗体. 根据第 1 节的第 3) 步的方法取  $N_c = 12$ , 更新记忆抗体  $M$ .

4) 判断收敛条件. 若连续 20 代记忆抗体适应度的平均值不变即满足收敛条件, 输出相应的最优参数, 停止搜索; 若不满足收敛条件转入 5) 继续搜索.

5) 克隆操作. 按第 1 节的 1) 步骤的方法, 求抗体的克隆算子  $q_i$ .

6) 变异成熟操作. 由第 1 节的 2) 步骤对抗体进

行高频变异成熟操作, 生成抗体群  $B_t$ .

7) 对于群体  $B_t$ , 若满足  $|B_t| > 4N_0$ , 按第 1 节的 4) 步对抗体进行浓度调节, 使得抗体群  $B_t$  的总数  $N_t = \lfloor |B_t| / 4 \rfloor$ , 并重新生成  $d = \lfloor |B_t| / 5 \rfloor$  个新抗体加入到群体  $B_t$  中.

8) 由记忆抗体群  $M$  和  $B_t$  生成下一代的群体  $A_{t+1}$ , 使  $t = t + 1$ , 转入 2), 进行循环操作.

### 3 仿真分析

基于模糊神经网络, 本文所设计的非线性控制器不需要量化输入状态变量, 和传统的模糊控制器结构不完全相同, 还将误差变化率的状态变量线性反馈到输入端, 如图 2 所示. 倒立摆是典型的非线性控制对象, 本文用新型控制器对其控制, 进行仿真实验, 以便说明设计的控制器在非线对象控制中的有效性. 倒立摆的动力学方程为

$$(M + m)\ddot{m} + m l \cos(\theta) \ddot{\theta} = -b\dot{x} + m l^2 \sin(\theta) + u \\ m l \ddot{\theta} \cos(\theta) + (I + m l^2) \ddot{\theta} = -f\dot{\theta} + m l g \sin(\theta).$$

式中:  $u$  为控制量 (作用在小车上的力),  $x$  为小车位移,  $\theta$  为摆杆与垂直方向的夹角,  $g = 9.8 \text{ m/s}^2$  为重力加速度. 倒立摆模型的其他参数为: 小车质量  $M = 1.096 \text{ kg}$ ; 摆杆质量  $m = 0.109 \text{ kg}$ ; 小车的摩擦系数  $b = 0.1 \text{ N/m} \cdot \text{s}^{-1}$ ; 摆杆轴心到质心的长度  $l = 0.25 \text{ m}$ ; 摆杆惯量  $I = 0.0034 \text{ kg} \cdot \text{m}^2$ ; 摆杆摩擦阻力矩系数  $f = 0.00218 \text{ kg} \cdot \text{m/s}^2$ . 易知该倒立摆有 4 个状态变量: 小车的位移  $x$ , 摆杆角度  $\theta$ , 小车速度  $\dot{x}$ , 摆杆角速度  $\dot{\theta}$ . 控制的目标是使单级倒立摆从某一初始状态能回到平衡位置  $(0, 0, 0, 0)$ .

不同于文献 [15] 控制器的设计方法, 本文直接把小车位移和摆杆角度  $(x, \theta)$  作为模糊神经网络的输入端, 把小车速度和摆杆角速度  $(\dot{x}, \dot{\theta})$  作为误差变化率, 通过线性反馈给控制量  $u$ . 设小车位移和摆杆角度各有“正”、“零”、“负”3 个模糊语言值, 形成 9 条模糊规则. 假设小车位移正模糊集、零模糊集、负模糊集高斯型隶属函数参数为  $(\bar{x}_{11}, \sigma_{11})$ ,  $(\bar{x}_{12}, \sigma_{12})$ ,  $(\bar{x}_{13}, \sigma_{13})$ ; 相应地, 摆杆角度各模糊集参数为  $(\bar{x}_{21}, \sigma_{21})$ ,  $(\bar{x}_{22}, \sigma_{22})$ ,  $(\bar{x}_{23}, \sigma_{23})$ . 为表示方便, 以  $x_1$ 、 $x_2$  分别表示小车位移和摆杆角度的模糊语言值, 以  $y$  表示控制器输出的模糊语言值. 由此模糊控制器的规则可以表示为: if  $x_1$  and  $x_2$  then  $y$  的形式, 每条规则对应如下的高斯算子:

$$\begin{aligned} z^1 &= \exp\left\{\frac{(x-\bar{x}_{11})^2}{2_{11}}-\frac{(-\bar{x}_{21})^2}{2_{21}}\right\}, \\ z^2 &= \exp\left\{\frac{(x-\bar{x}_{11})^2}{2_{11}}-\frac{(-\bar{x}_{22})^2}{2_{22}}\right\}, \\ z^3 &= \exp\left\{\frac{(x-\bar{x}_{11})^2}{2_{11}}-\frac{(-\bar{x}_{23})^2}{2_{23}}\right\}, \\ z^4 &= \exp\left\{\frac{(x-\bar{x}_{12})^2}{2_{12}}-\frac{(-\bar{x}_{21})^2}{2_{21}}\right\}, \\ z^5 &= \exp\left\{\frac{(x-\bar{x}_{12})^2}{2_{12}}-\frac{(-\bar{x}_{22})^2}{2_{22}}\right\}, \\ z^6 &= \exp\left\{\frac{(x-\bar{x}_{12})^2}{2_{12}}-\frac{(-\bar{x}_{23})^2}{2_{23}}\right\}, \\ z^7 &= \exp\left\{\frac{(x-\bar{x}_{13})^2}{2_{13}}-\frac{(-\bar{x}_{21})^2}{2_{21}}\right\}, \\ z^8 &= \exp\left\{\frac{(x-\bar{x}_{13})^2}{2_{13}}-\frac{(-\bar{x}_{22})^2}{2_{22}}\right\}, \\ z^9 &= \exp\left\{\frac{(x-\bar{x}_{13})^2}{2_{13}}-\frac{(-\bar{x}_{23})^2}{2_{23}}\right\}, \end{aligned}$$

$$u=\frac{\sum_{i=1}^9 z^i \vec{y}^i}{\sum_{i=1}^9 z^i}+k_1 \dot{x}+k_2 \ddot{x} \quad(18)$$

所要求的参数序列为  $(\bar{x}_{11}, \quad_{11}, \bar{x}_{12}, \quad_{12}, \bar{x}_{13},$   
 $_{13}, \bar{x}_{21}, \quad_{21}, \bar{x}_{22}, \quad_{22}, \bar{x}_{23}, \quad_{23}, \vec{y}^1, \vec{y}^2, \vec{y}^3, \vec{y}^4, \vec{y}^5, \vec{y}^6, \vec{y}^7,$

表 1 改进的非线性控制器最优参数

Table 1    Optimal parameters of the improved nonlinear controller

推理规则	$x_1$ 语言值	$x_{1j}$ 中心	$x_{1j}$ 方差	$x_2$ 语言值	$x_{2j}$ 中心	$x_{2j}$ 方差	$y_f$ 中心
1	正	1.134 0	0.636 7	正	0.746 2	0.909 1	344.175 0
2	正	1.134 0	0.636 7	0	0.028 5	0.564 3	-2.809 8
3	正	1.134 0	0.636 7	负	-1.321 5	0.897 7	-205.939 9
4	0	0.059 1	0.362 0	正	0.746 2	0.909 1	164.942 9
5	0	0.059 1	0.362 0	0	0.028 5	0.564 3	1.796 1
6	0	0.059 1	0.362 0	负	-1.321 5	0.897 7	-249.280 8
7	负	-0.452 1	0.861 1	正	0.746 2	0.909 1	35.771 4
8	负	-0.452 1	0.861 1	0	0.028 5	0.564 3	-55.435 1
9	负	-0.452 1	0.861 1	负	-1.321 5	0.897 7	-374.022 6

注： $x_{1j}, x_{2j}, y_f$ 表示小车位移、摆杆角度、控制器输出对应的隶属函数

表 2 m-A Net和 m-CSA 的性能对比

Table 2    The performance comparison in m-A Net and m-CSA

算法	最大计算函数次数	最小计算函数次数	平均最优值	方差	$N1/N2/N3$	获得最优解的次数
m-A Net	2 520	1 846	0.192 0	$5.14 \times 10^{-3}$	46/23/30	30
m-CSA	1 564	985	0.204 1	$1.35 \times 10^{-3}$	25/15/18	30

注： $N1/N2/N3$ 表示获得最优解时需要迭代的最大次数/平均次数/最小次数

$\vec{y}^8, \vec{y}^9, k_1, k_2)$ . 把表示小车位移和倒立摆模糊语言“正”、“零”、“负”的中心调节范围分别限定在区间 $[0.2, 2], [-0.3, 0.3], [-2, -0.2]$ , 其方差调节区间分别为 $[0.5, 2], [0.4, 1], [0.4, 2]$ .  $(\vec{y}^1, \vec{y}^2, \dots, \vec{y}^9, k_1, k_2)$ 的调节区间分别为 $[20, 400], [-80, 80], [-400, 0], [10, 200], [-20, 20], [-400, 20], [10, 100], [-100, 100], [-400, 0], [10, 60], [10, 60]$ . 取倒立摆的初始状态为 $(0.6, 0.5, 0, 0)$ , 二次型性能指标参数为: $Q = \text{diag}(10, 1, 0, 0)$ ,  $R = 0.01$ , 按式(16)和(17)计算抗体的评价价值.

运用 m-CSA 算法优化这些参数时, 取初始群体总数  $N_0 = 30$ , 常数  $N_c = 12$ , 权值  $w = 0.2$ , 搜索的最大次数设为  $\text{gen} = 50$ . 搜索最优参数过程如图 3 所示. 为了对比, 本文还将所改进的免疫克隆选择算法和文献[10]提出的改进型 m-A Net 免疫算法做对比, 分别独立运行 30 次, 得到表 2 和图 3 所示的对比情况. 最终得到控制器参数如表 1 所示. 其中小车速度和摆杆角速度的反馈系数分别为  $k_1 = 37.328$ ,  $k_2 = 23.740 9$ . 将确定最优参数后的控制器控制不同初始状态的倒立摆系统, 得到如下图 4 至图 6 所示的各响应曲线.






图 3 控制器参数寻优过程


Fig 3 The performance of controller's parameter optimization



(a) 小车位移的响应曲线




(b) 摆杆角度的响应曲线




(c) 控制器的输出曲线

图 4 初始状态 (0.65, 0.7, 0.0) 的响应曲线


Fig 4 The response curve when the initial state is (0.65, 0.7, 0.0)



(a) 摆杆角角度的响应曲线




(b) 摆杆角度的响应曲线




(c) 控制器的输出曲线

图 5 初始状态 (0.65, 0.7, 0.0) 的响应曲线


Fig 5 The response curve when the initial state is ( - 0.5, - 0.4, 0.0 )



(a) 小车位移的响应曲线



(b) 摆杆角度的响应曲线



(c) 控制器的输出曲线

图 6 初始状态 (0.1, -0.2, 0.0) 的响应曲线

Fig 6 The response curve when the initial state is (0.1, - 0.2, 0.0 )

由仿真图可知,将误差变化率做线性补偿的模糊神经网络控制器,用改进的免疫克隆选择算法进行参数寻优取得很好的效果,该控制器能够控制不同状态的倒立摆这样典型的非线性控制对象,非线性适应能力强,可以作为非线性智能控制器的一种设计方法。

## 4 结束语


本文通过改进抗体的变异操作,并采取抗体熵函数和适应度加权的方法,在对抗体进行抑制操作时将其作为抗体选择的评价值,从而提出了改进的免疫克隆算法,由图 3 可知该算法在所设计的非线性控制器参数寻优过程中比 m-ANet 免疫算法<sup>[10]</sup>具有更明显的优势;此外,本文基于模糊神经网络,结合误差线性反馈,将误差的变化率作为补偿输入到控制器的另外输入端最后将它们相加,设计了一种新型的非线性控制器;倒立摆的仿真实验表明,确定最优参数后,控制器具有很强的非线性适应能力,而且不需要量化输入的状态变量,调节参数较容易,可以作为非线性控制器设计的参考方法。

## 参考文献:

- [1] WANG Lixin. Design and analysis of fuzzy identifiers of nonlinear dynamic systems[J]. IEEE Transactions on Automatic Control, 1995, 40(1): 11-23.
- [2] 李涛. 计算机免疫学[M]. 北京:电子工业出版社, 2004: 39-40.
- [3] 胡江强, 郭晨, 李铁山. 启发式自适应免疫克隆算法[J]. 哈尔滨工程大学学报, 2007, 28(1): 1-5.  
HU Jiangqiang, GUO Chen, LI Tieshan. Heuristic adaptive immune clone algorithm[J]. Journal of Harbin Engineering University, 2007, 28(1): 1-5.
- [4] BURNET F M. The clonal selection theory of acquired immunity[M]. Cambridge, UK: Cambridge Univ Press, 1959: 45-140.
- [5] De CASTRO L N, TMM IS J. An artificial immune network for multimodal function optimization[C]// Proceedings of the 2002 Congress on Evolutionary Computation. Honolulu, HI, USA, 2002: 699-704.
- [6] De CASTRO L N, Von ZUBEN F J. Learning and optimization using the clonal selecting principle[J]. IEEE Transactions on Evolutionary Computation, 2002, 6(3): 239-251.
- [7] De CASTRO L N, VON ZUBEN F J. Data mining: a heuristic approach[M]. Sydney, Idea Group Publishing, Univ New South Wales, 2001: 24-70.

- [8] TAN K C, GOH K, MAMUN A A. An evolutionary artificial immune system for multiobjective optimization[J]. European Journal of Operational Research, 2008, 187: 371-392.
- [9] 焦李成, 杜海峰, 刘芳, 等. 免疫优化计算、学习与识别[M]. 北京: 科学出版社, 2006: 61-62.
- [10] CAMPELO F, GU MARAES F G, IGARASHI H, et al. A modified immune network algorithm for multimodal electromagnetic problems[J]. IEEE Transactions on Magnetics, 2006, 42(4): 1111-1114.
- [11] FUKUDA T, MORI K, TSUKAMA M. Artificial immune systems and their applications[M]. [S. L.], Springer-Verlag, 1999: 210-229.
- [12] CHUN J S, JUNG H K, HAHN S Y. A study on comparison of optimization performances between immune algorithm and other heuristic algorithm[J]. IEEE Transactions on Magnetics, 1998, 34(5): 2972-2975.
- [13] CUI X, LIM, FANG T. Study of population diversity of multi-objective evolutionary algorithm based on immune and entropy principles[C]// Proceedings of the 2001 Congress on Evolutionary Computation. Seoul, South Korea, 2001: 1316-1321.
- [14] 王立新. 模糊系统与模糊控制教程[M]. 北京:清华大学出版社, 2003: 133-134.
- [15] ZUO X Q, LI S Y. The chaos artificial immune algorithm and its application to RBF neuro-fuzzy controller design[C]// IEEE International Conference on System, Man and Cybernetics. Washington, DC, USA, 2003: 2809-2814.

## 作者简介:



黄忠报,男,1981年生,硕士研究生,主要研究方向为人工免疫智能算法、非线性控制。



李士勇,男,1943年生,教授,博士生导师,中国自动化学会智能自动化专业委员会委员,《计算机测量与控制》编委。主要研究领域为模糊控制、神经控制、智能控制、智能优化算法、非线性科学与复杂性科学等。在国内外发表学术论文 120 余篇,编著教材与专著共 5 部。