

混沌系统的遗传神经网络控制*

王耀南¹⁾ 谭文¹⁾²⁾

¹⁾ 湖南大学电气与信息工程学院,长沙 410082)

²⁾ 湖南科技大学信息与电气工程学院,湘潭 411201)

(2002 年 11 月 4 日收到,2003 年 2 月 28 日收到修改稿)

提出遗传神经网络控制混沌新方法. 将小扰动技术和周期控制技术结合起来,用遗传算法训练神经网络,使之成为混沌控制器. 对 Henon 映射和 Logistic 映射的仿真结果说明控制器能产生小扰动控制序列信号,将混沌振荡转变成规则运动状态. 该方法无需了解动态系统数学模型,具有一定抗噪声干扰能力,可将它推广应用到其他混沌系统的控制中.

关键词:遗传算法,神经网络,混沌,周期控制

PACC: 0545

1. 引 言

混沌现象是确定性非线性运动,其行为轨迹非常复杂但又不完全随机. 对大多数系统而言,它的存在往往是有害的,因此采用某些方法去消除混沌,已成为混沌应用的关键技术. 前人在这方面做了许多有益的研究工作^[1-8].

神经网络具有能以任意精度逼近复杂非线性函数、强的鲁棒性和容错性、大规模并行性和能学习与适应严重不确定系统的动态特性等优势,引起了控制领域广泛关注. 近年来,应用神经网络控制混沌系统已取得了一些成果^[3-6],所采用的是多层前馈神经网络模型. 由于用反向传播算法,训练网络收敛速度慢,且不可避免会遇到局部极小问题. 随着人工智能学科的发展,将遗传算法(GA)用于神经网络结构和权系数的优化及利用遗传算法进行模糊控制器的辅助设计,已成为目前一个非常重要的应用方向.

本文用改进遗传算法优化神经网络权系数方法,使之成为混沌控制器,将混沌系统变成规则运动. 该方法无需了解系统数学模型及维数和不动点的位置,操作简单,仿真实验结果表明控制极为有效.

2. 小扰动控制混沌

非线性动力系统的混沌现象是由某些参数的变

化引起,因此关于混沌控制的一种十分自然的想法便是直接调整或控制这些参数. 1990 年 Ott 等人提出了将混沌状态转变为所期望的不稳定周期态的参数扰动法(简称 OGY 方法),它是建立在混沌吸引子中镶嵌有无穷多个不稳定周期轨道理论上,利用混沌运动对很小的参数扰动敏感和混沌运动各态遍历性,给系统一个较小的参数扰动控制量,把混沌系统控制到某一周期轨道. Lima 和 Pettini 指出通过给参数以一定频率的扰动,可以把系统的混沌状态变成规则运动状态,从而实现混沌控制^[8]. 上述方法是根据小扰动技术达到混沌控制目的.

考虑如下递归映射:

$$x_{n+1} = f(x_n; p), \quad (1)$$

其中 p 为系统外部扰动参数, x_n, x_{n+1} 为第 n 次、 $n+1$ 次迭代的状态变量. 依据上面提到的方法,对系统参数进行微扰,受控后的映射可表示为

$$x_{n+1} = f(x_n; p) + \delta p, \quad (2)$$

其中 δp 为系统参数随时间变化值.

神经网络无需受控系统的数学模型,因此用它作为复杂系统控制器已引起人们极大兴趣. 本文目标是设计神经网络控制器,利用遗传算法全局优化能力训练网络,使其输出小扰动控制信号 δp , 达到实现抑制混沌目的.

* 国家自然科学基金(批准号 60075008 和 60102010)资助的课题.

3. 遗传神经网络控制器结构

人工神经网络的研究已走过了相当长的时期,至今已有的各种神经网络结构中,研究和应用最多的是前馈网络.其训练问题实际上是寻找最优的结构和连接权值,使网络的输出与目标函数之差极小,属于优化问题,故可以采用遗传算法来训练它.




图 1 网络拓扑结构

本文采用遗传算法训练神经网络权值,使网络输出能有效地控制混沌系统状态.网络拓扑结构如图 1 所示.其中第一层为输入层,有 n 个输入节点;第二层为含 h 个节点的隐层,该层第 i 个节点输出为

$$o_i = g\left(\sum_{j=1}^n a_{ij}x_j\right), \quad (3)$$

其中 $g(s) = \frac{1}{1 + e^{-s}}$, a_{ij} 为输入层第 j 个节点与隐层第 i 个节点连接权值.输出层关系为

$$y = g\left(\sum_{j=1}^n b_jx_j + \sum_{i=1}^h c_i o_i\right). \quad (4)$$

网络控制器中每个连接权用一个实数表示,则整个网络对应图 1,用染色体具体表示如图 2.




图 2 神经网络染色体编码

4. 遗传算法

遗传算法是模拟达尔文的遗传选择和自然淘汰的生物进化过程的计算模型.遗传算法作为一种新的全局优化随机搜索算法,在个体基因表示基础上,通过遗传算子模拟遗传过程中所出现的复制、交叉、变异等现象,并根据适者生存的自然法则,对种群个体逐代择优,从而最终获得较优个体.算法实质是一种在解空间中搜索与环境最匹配解的自适应方法.由于其鲁棒性强,适合于并行处理以及具有不受问题性质(如连续性、可微性)的限制等显著特点,奠定了它作为 21 世纪关键智能计算方法之一的地位^[9].

基于上述认识,本文采用改进遗传算法优化神经网络权系数,亦即优化混沌控制器.

4.1. 初始群体确定

确定初始群体是遗传算法一个重要方面,若各个染色体之间的差异很小,会使群体失去多样性,导致算法早熟,进而使遗传算法的全局优化功能失效,为此本文采用一种改进选种方法:利用范数来度量群体中各染色体之间的差异,范数定义如下^[10]:

$$H = \|x_i - x_j\| = \left[\sum_{l=1}^m (x_{il} - x_{jl})^2 \right]^{\frac{1}{2}}, \quad (5)$$

其中 m 为染色体的基因位数, x_i, x_j 为群体中两个不同的染色体. H 越大,两点之间的相似性越差,反之相似性越好.该选种策略即确定一个染色体作为基准,求得群体中其他染色体与基准染色体的距离 H ,使之大于事先设定值,保证各染色体之间有较大差异,从而保证初始群体的多样性,进而保证遗传算法能搜索到全局最优解.

4.2. 编码方案

遗传算法求解问题的另一个重要步骤是确定它的表示方案,即编码.目前常用的编码方法是二进制编码,但该编码方式在求解多维高精度问题时需要占用大量存储空间,且在解码上消耗过多时间,使计算性能下降.因此这里采用编码直观、遗传操作简单、编程容易实现的实数编码.具体表达式如下:设 x_i 为一染色体,令

$$x_i = (x_{i1}, x_{i2}, \dots, x_{im}), \quad i = 1, 2, \dots, P, \quad (6)$$

$x_{i1}, x_{i2}, \dots, x_{im}$ 为随机产生的在范围 $[x_{\min}, x_{\max}]$ 内的

共 m 个实数,称为染色体的基因.每个基因 x_{il} 代表一个连接权,该染色体代表一个网络. P 为遗传算法的群体规模.

4.3. 自适应选择

选择算子是整个算法的关键,它来源于自然界适者生存的思想.经典遗传算法中的选择通常是直接根据适配值的大小决定选择概率,如轮盘赌法.但当种群接近收敛时,个体之间适配值相差较小,直接根据适配值决定选择概率显然会导致更优良的串在竞争中体现不了优势,致使遗传算法求解精度低.由此提出如下选择策略:

挑选出种群中的最小适配值,将种群中所有个体的适配值都减去该最小适配值,然后根据新的适配值采用轮盘赌法进行选择.该策略在计算过程中动态地改变了每个串的适配值,符合自然规则:个体生存环境改变,评判标准也随之发生变化.

4.4. 杂交算子选择

选择算子在提高了群体的平均适应度的同时又是以损失群体的多样性为代价的,为解决这个问题,遗传算法又引入了杂交算子和变异算子.杂交算子体现了自然界中信息交换的思想,它每次作用在随机选择的两个个体上,使这两个个体的某一段基因互换,产生两个新的个体,提高了群体的多样性,从而增大了搜索空间,有效地避免了局部最优.本文采用的杂交策略是一种适合于实数编码的杂交方法:产生一个 $(0, 1)$ 之间的随机数 γ ,在新产生的群体中随机选择两个染色体 X_1 和 X_2 进行杂交,得到两个新染色体为

$$\begin{aligned} X^1 &= \gamma X_1 + (1 - \gamma) X_2, \\ X^2 &= \gamma X_2 + (1 - \gamma) X_1. \end{aligned} \quad (7)$$

4.5. 自适应变异及变异算子

根据各代平均适配值变化率的情况来决定变异率的大小,如果适配值变化率大,那么提高变异率,反之则减小变异率.它体现出在进化过程中,若适配值变化率大,则基因存在较大缺陷,需作较大调整,由此给出如下变异率公式:

$$p_m(k) = \mu \exp(-\beta |\Delta f(k)|), \quad (8)$$

其中 μ 和 β 为常数, $p_m(k)$ 为算法执行到第 k 代时采用的变异概率, $\Delta f(k)$ 为第 k 代与第 $k-1$ 代的平均适配值之差.(8)式保证了算法在执行初始阶段采

用较大的变异率,扩展了搜索空间,也使得算法结束阶段变异率较小,保证了算法的收敛性.变异算子以该变异率随机地改变个体的某一部分,产生一个新的个体,起到增加群体多样性的效果.本文变异策略为:产生一个 $[1, m]$ 上的整数 r 及 $[x_{\min}, x_{\max}]$ 上的随机数 x ,将该数 x 加到染色体 X_i 的第 r 位基因 x_{ir} 上,从而产生一个新的染色体.

4.6. 个体适配值函数的选取

遗传算法作为一种随机搜索算法,它与对象联系主要体现在适配值函数上,是算法和对象沟通信息的基本桥梁,它的选取体现了对优化对象和目的把握程度.本文算法用适配值函数来评价每个神经网络控制器镇定混沌系统的能力,目标是找到一个网络,将系统混沌状态转化为规则运动,该适配值函数可以通过观测受控系统状态来确定网络控制器性能.由此构造如下适配值函数:

$$\text{fitness} = A \cdot \text{fitness}_1 + B \cdot \text{fitness}_2, \quad (9)$$

其中 A, B 为与系统无关的可调参数,式中每一部分取值由受控对象经过多次迭代后的行为特性确定.其中 fitness_1 根据网络最终是否将混沌系统稳定到了不动点决定.令

$$\Delta_n = \frac{|x_n - x_{n-1}|}{s}, \quad (10)$$

其中 x_n 为第 n 次迭代的状态变量, s 为不可控吸引子大小,于是 fitness_1 表示为

$$\text{fitness}_1 = 1 - [\Delta_n], \quad (11)$$

其中 $[\Delta_n]$ 为取迭代映射最后数个 Δ_n 的平均值,这样当系统状态接近或到达不动点时, Δ_n 很小, fitness_1 很大. fitness_2 反映了迭代映射接近不动点时 Δ_n 的变化率,如果 Δ_n 小于规定的较小值 ρ ,那么该值被保存起来,直到它大于某一设定值为止. fitness_2 用下式表示:

$$\text{fitness}_2 = 1 - \ln(\alpha), \quad (12)$$

其中 \ln 为取自然对数, α 为对所有保存起来的 Δ_n 计算 Δ_n / Δ_{n-1} 几何平均的结果.当网络控制器将混沌状态引导至不动点时, $\alpha \approx 1$,如果迭代过程所有 Δ_n 均不小于 ρ ,则 α 无定义,此时 $\text{fitness}_2 = 0$.

对于高周期轨道的控制,本文提出一种称之为周期控制策略.此时重新定义(10)式为

$$\Delta_n = \frac{|x_n - x_{n-N}|}{s}, \quad (13)$$

则 N 周期轨道便可按该方法进行控制. 不同于周期 1 轨道控制, 每次迭代都对系统施加控制作用. 该策略是映射每迭代 N 次才对系统施加一次扰动. N 周期轨道的 N 个位置均可作为初始迭代点, 它的选取决定了周期控制效果. 即每迭代 N 次再让控制器投入工作, 使系统保持在 N 周期轨道的某一点上, 然后撤去控制信号使系统自由演化到周期轨道其他点.

5. 仿真实验及结果

应用遗传神经网络控制器控制两个混沌系统, Henon 映射和 Logistic 映射的周期 1、周期 2 和周期 4 轨道, 证明该方法的有效性.

5.1. 控制 Henon 映射

Henon 映射是关联维数约等于 1.25 的二维映射, 表达式为

$$x_{n+1} = A - x_n^2 + Bx_{n-1}. \quad (14)$$

当(14)式中 $A = 1.29, B = 0.3$ 时, 系统(14)产生混沌, 系统混沌状态相图如图 3 所示. 将学习后的神经网络控制器输出小扰动 δp 加到(14)式, 有

$$x_{n+1} = (A + \delta p) - x_n^2 + Bx_{n-1}. \quad (15)$$

控制目标是将 Henon 映射引到不稳定周期 1 轨道(即不动点). 网络拓扑结构如图 1 所示, 三个输入节点, 其中两个输入状态: x_n, x_{n-1} 为 Henon 映射在第 n 及第 $n-1$ 次迭代值, 另一个输入是固定值为 0.5 偏置节点. 隐层含 5 个节点, 1 个输出节点, 因此每个网络有 23 个权值. 学习参数为: 最大扰动量 $\delta p_{max} = 0.01$, 种群大小为 100, $p_c = 0.786$, 控制器输出经过下式变换:

$$\delta p = \delta p_{max}(2y - 1). \quad (16)$$

由于 $0 < y < 1$, 则作用在系统上的扰动控制量 $|\delta p| < \delta p_{max}$. 实验过程将均值为零而强度为 $\epsilon = 0.01$ 的噪声加入到了状态变量 x 中. 图 3 为系统相图. 图 4 为最大扰动量 $\delta p_{max} = 0.01$ 时神经网络控制器进化学习时的适应度随进化代数变化情况. 图 4 显示出种群经过约 500 代可找到一个适应度较大的神经网络控制器. 图 5 为学习完成后控制器将混有噪声强度 $\epsilon = 0.01$ 的 Henon 映射不稳定周期轨道控制在不动点的情形. 图 6 为对应控制器输出扰动控制信号. 不难发现系统一旦被锁定在不动点, 即使存在噪声, 很小的扰动控制便可使系统状态保持在稳定控制状

态之下.




图 3 Henon 映射相图




图 4 噪声强度为 0.01 时网络进化适应度




图 5 Henon 映射受控后周期 1 轨道

5.2. 控制 Logistic 映射

Logistic 映射是一个一维映射, 常用来建立人口




图 6 控制输出扰动信号




图 8 Logistic 映射受控后周期 1 轨道

动态模型 表达式为

$$x_{n+1} = \lambda x_n(1 - x_n). \quad (17)$$

当参数 $\lambda = 3.79$ 时,系统 (17) 产生混沌. 周期 1 轨道不动点 $x_{F1} = 0.736148$. 周期 2 轨道不动点 $x_{F21} = 0.375293$, $x_{F22} = 0.888559$. 实验参数同上, 图 7 为系统相图. 加入小扰动控制后映射为

$$x_{n+1} = \lambda x_n(1 - x_n) + \delta\lambda. \quad (18)$$

图 8 为 Logistic 映射受控后的周期 1 轨道, 它表明只要加入控制器, 受控后的轨道可维持在不动点 x_{F1} 附近. 周期 2 轨道控制采用周期控制策略, 即系统每迭代两次再加入小扰动控制, 使系统稳定在某个周期点上, 然后撤去控制器, 让系统自由演化到另一个周期点. 图 9 为受控后周期 2 轨道曲线, 控制过程该轨道极其稳定. 图 10 为将 Logistic 映射控制到 4 周期轨道, 可注意到控制过程受控轨道高度稳定, 撤去扰动, 系统立即恢复混沌状态.




图 9 Logistic 映射受控后周期 2 轨道




图 7 Logistic 映射相图




图 10 Logistic 映射受控后周期 4 轨道

6. 结 论

提出遗传神经网络控制混沌新方法. 将小扰动

技术和周期控制技术结合起来,用遗传算法训练神经网络,使之成为混沌控制器.仿真结果说明控制器能产生小扰动控制序列信号,将混沌振荡转变成规则运动状态,包括周期 1、周期 2 和周期 4 轨道.由于

该方法无需了解动态系统的数学模型及其他特性(如不动点位置和状态维数),加之具有一定抗干扰能力,故可将它推广应用到其他混沌系统的控制中.

- [1] Zhang J S *et al* 2001 *Chin. Phys.* **10** 97
- [2] Luo X S 2001 *Chin. Phys.* **10** 17
- [3] He G G *et al* 2001 *Acta Phys. Sin.* **50** 2103 [in Chinese] 何国光等 2001 物理学报 **50** 2103]
- [4] Tan W *et al* 2002 *Acta Phys. Sin.* **51** 2463 [in Chinese] 谭文等 2002 物理学报 **51** 2463]
- [5] Alsing P M, Gavrielides A and Kovanis V 1994 *Phys. Rev. E* **49** 1225
- [6] Eric R, Weeks J and Burgess M 1997 *Phys. Rev. E* **56** 1531
- [7] Chen S H *et al* 2002 *Acta Phys. Sin.* **51** 749 [in Chinese] 陈士华等 2002 物理学报 **51** 749]
- [8] Lima R and Pettini M 1990 *Phys. Rev. A* **41** 726
- [9] Wang Y N 1999 *Computational Intelligent Information Processing Technology and Applications* (Changsha :Hunan University Press) [in Chinese] 王耀南 1999 计算智能信息处理技术及其应用 (长沙 湖南大学出版社)]
- [10] David B F 1994 *IEEE Transaction Neural Network* **1** 3

Genetic-based neural network control for chaotic system *

Wang Yao-Nan¹⁾ Tan Wen^{1 2)}

¹⁾ College of Electrical and Information Engineering, Hunan University, Changsha 410082, China)

²⁾ School of Information and Electrical Engineering, Hunan University of Science and Technology, Xiangtan 411201, China)

(Received 4 November 2002 ; revised manuscript received 28 February 2003)

Abstract

A novel genetic-based neural network control for chaos is presented. The method proposed has been successfully applied to control two simulated chaotic systems by incorporating the techniques of small perturbations and the periodic control in this paper. The simulation results showed that the neural network trained by genetic algorithm can learn to produce a series of small perturbations to convert chaotic oscillations of a chaotic system into desired regular ones. The scheme requires no knowledge about the mathematical model. Moreover, the approach is reasonably robust to noise, it can be extended to control other chaotic systems.

Keywords : genetic algorithm, neural network, chaos, periodic control

PACC : 0545

* Project supported by the National Natural Science Foundation of China (Grant Nos. 60075008 and 60102010).