

基于免疫粒子群优化的一种动态递归神经网络辨识与控制非线性系统

葛宏伟¹, 李小琳², 梁艳春³, 何湘东⁴

(1. 大连理工大学 电子与信息工程学院, 辽宁 大连 116024; 2. 南京大学 商学院, 南京 210093; 3. 吉林大学 计算机科学与技术学院, 长春 130012; 4. 中兴通讯南京研究所, 南京 210012)

摘要:提出了一种采用免疫粒子群优化算法对动态递归神经网络进行训练的方法, 实现了对Elman网络的结构、权重、结构单元的初始输入和自反馈增益因子等参数的同时进化训练。进而针对非线性系统分别提出了相应的辨识与控制算法, 并设计出了相应的辨识器和控制器。最后以超声马达为对象进行了仿真, 结果表明: 基于所提出的算法而设计的辨识器和控制器在辨识和控制过程中不仅都能取得很高的收敛精度和速度, 而且对于随机扰动有较强的鲁棒性, 从而为非线性系统的辨识和控制提供了一条新的途径。

关键词:人工智能; 控制理论; 动态递归神经网络; 粒子群优化; 免疫系统; 超声马达

中图分类号: TP18 **文献标识码:** A **文章编号:** 1671-5497(2008)04-0858-07

Immune PSO-based dynamic recurrent neural network for identifying and controlling nonlinear systems

GE Hong-wei¹, LI Xiao-lin², LIANG Yan-chun³, HE Xiang-dong⁴

(1. College of Electronic and Information Engineering, Dalian University of Technology, Dalian 116024, China; 2. School of Business, Nanjing University, Nanjing 210093, China; 3. College of Computer Science and Technology, Jilin University, Changchun 130012, China; 4. ZTE Corporation R&D Nanjing, Nanjing 210012, China)

Abstract: A learning algorithm for dynamic recurrent Elman neural networks was presented, which is based on an immune particle swarm optimization (PSO). The algorithm computed concurrently the evolution of network structure, weight, initial inputs of the context units and the self-feedback coefficient of the modified Elman network. Thereafter, a novel control method based on the proposed algorithm was introduced and discussed. More specifically, a dynamic identifier was constructed to perform speed identification, and a controller was designed to perform speed control for Ultrasonic Motors (USM). Numerical experiments show that the identifier and the controller based on the proposed algorithm can both achieve higher convergence precision and convergence rate than those based on other state-of-the-art algorithms. In particular, the experiments show that the identifier can approximate the USM's nonlinear input-output mapping accurately. The effectiveness of the controller is verified using constant speed, step and sinusoidal changing speeds.

收稿日期: 2007-03-21.

基金项目: 国家杰出青年科学基金项目(60625302); “973”国家重点基础研究发展规划项目(2002CB3122000); “863”国家高技术研究发展计划项目(2006AA04Z168); 国家自然科学基金项目(60433020).

作者简介: 葛宏伟(1977-), 男, 博士, 研究方向: 人工神经网络, 进化计算, 计算机应用. E-mail: art21cn@163.com

通信作者: 李小琳(1978-), 女, 讲师, 研究方向: 机器学习, 数据挖掘. E-mail: lixl_126@126.com

Key words: artificial intelligence; control theory; dynamic recurrent neural network; particle swarm optimization; immune system; ultrasonic motor

系统辨识是控制理论研究的一个重要分支,也是控制理论能否成功应用于实际的关键之一。超声马达(ultrasonic motor, USM)是一个典型的非线性系统,它具有许多优良特性,在目前得到广泛的应用。在超声马达的实际应用过程中,它的辨识与控制是人们经常遇到而又不可避免的问题。若按常规的控制理论,需对超声马达建立精确的数学模型,但影响马达工作状态的因素有很多,而且其摩擦机理至今尚未完全弄清,所以很难建立精确的数学模型。神经网络所具有的非线性变换特性和高度的并行运算能力为系统辨识和控制(尤其是非线性系统的辨识和控制)提供了有效的方法^[1]。若直接用前馈网络作为非线性动态系统辨识模型,由于网络的输出仅仅是当前输入的非线性映射,实际上也是将动态时间建模问题变为一个静态空间建模问题。这就必然出现诸多问题,如需要先验假定系统的 NARMA 模型类;需要对结构模型进行定阶;特别是随着系统阶次的增加,或阶次未知时,迅速膨胀的网络结构将使学习收敛速度更加缓慢;较多的输入节点也会使相应的辨识系统对外部噪声特别敏感。而利用多层动态递归神经网络引入了动态环节,能够自动记忆部分历史影响信息,从而避免了这些问题。因此,动态递归神经网络是控制系统建模、辨识和控制中极具发展潜力的网络^[2-3]。作者利用 Elman 网络模型^[4]结合提出的免疫粒子群优化算法,对超声马达的速度进行辨识和控制。

1 Elman 网络

Elman 网络结构如图 1 所示,它除了输入层,隐层和输出层之外,还有一个用来记忆隐层单元以前时刻的输出值的特殊的结构单元。设网络的输入层为 r 个节点,隐层和结构单元为 n 个节点,输出层为 m 个节点,则网络输入 \mathbf{u} 为 r 维向量,隐层输出 \mathbf{x} 及结构单元输出 \mathbf{x}_c 为 n 维向量,网络输出 \mathbf{y} 为 m 维向量,连接权 \mathbf{W}^1 为 $n \times n$ 维矩阵, \mathbf{W}^2 为 $n \times r$ 维矩阵, \mathbf{W}^3 为 $m \times n$ 维矩阵。

网络的数学模型为

$$\mathbf{x}(k) = f(\mathbf{W}^1 \mathbf{x}(k) + \mathbf{W}^2 \mathbf{u}(k-1)) \quad (1)$$

$$\mathbf{x}_c(k) = \alpha \mathbf{x}_c(k-1) + \mathbf{x}(k-1) \quad (2)$$

$$\mathbf{y}(k) = \mathbf{W}^3 \mathbf{x}(k) \quad (3)$$

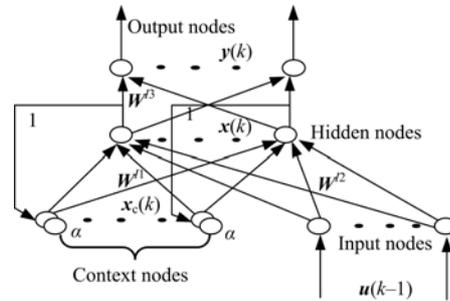


图 1 Elman 结构示意图

Fig. 1 Architecture of modified Elman network

式中: $f(x)$ 多取为 sigmoid 函数,即 $f(x) = 1/(1 + e^{-x})$; α 为自连接反馈增益因子 ($0 \leq \alpha < 1$), 当 α 固定为零时此网络为标准的 Elman 网络; α 不为零时,为修改的 Elman 网络。

设第 k 步系统的实际输出为 $\mathbf{y}_d(k)$, 定义误差函数 $E(k) = (\mathbf{y}_d(k) - \mathbf{y}(k))^T (\mathbf{y}_d(k) - \mathbf{y}(k)) / 2$, 将 E 对连接权 \mathbf{W}^3 、 \mathbf{W}^2 、 \mathbf{W}^1 分别求偏导, 由梯度下降法可得 Elman 网络的学习算法

$$\Delta w_{ij}^3 = \eta \delta_i^0 x_j(k) \quad (4)$$

$$i = 1, 2, \dots, m; j = 1, 2, \dots, n$$

$$\Delta w_{jq}^2 = \eta \delta_j^h u_q(k-1) \quad (5)$$

$$j = 1, 2, \dots, n; q = 1, 2, \dots, r$$

$$\Delta w_{jl}^1 = \eta \sum_{i=1}^m (\delta_i^0 w_{ij}^3) \frac{\partial x_j(k)}{\partial w_{jl}^1} \quad (6)$$

$$j = 1, 2, \dots, n; l = 1, 2, \dots, n$$

式中: $\delta_i^0 = (\mathbf{y}_{d,i}(k) - \mathbf{y}_i(k)) g'_i(\cdot)$ (7)

$$\delta_j^h = \sum_{i=1}^m (\delta_i^0 w_{ij}^3) f'_j(\cdot) \quad (8)$$

$$\frac{\partial x_j(k)}{\partial w_{jl}^1} = f'_j(\cdot) x_l(k-1) + \alpha \frac{\partial x_j(k-1)}{\partial w_{jl}^1} \quad (9)$$

式中: η 、 η 、 η 分别为 \mathbf{W}^1 、 \mathbf{W}^2 、 \mathbf{W}^3 的学习步长。

从以上动力学方程可知,由于隐层存在反馈连接,在任意给定时刻,网络的输出受到网络过去输入/输出的影响,直接用上述算法训练 Elman 网络,初始误差比较大,而且结构单元的初始输入通常是人为给定的,对结果的优化有一定程度的影响。此外,Elman 算法本身固有的缺陷在于:①学习速度较慢,且容易陷入局部极小值;②自反馈增益因子 α 通常由尝试法确定,导致学习效率较低;③需要先确定网络隐层单元数目再学习权

重,这样可能破坏 Kosmogorov 定理,不能保证三层网络的结构合理性,也就无法保证网络良好的动态逼近能力。针对这些问题,作者提出了一种免疫粒子群优化算法,实现了对 Elman 网络结构、权重、结构单元的初始输入和自反馈增益因子同时进化的学习算法,提高了动态神经网络模型的辨识和控制能力。

2 免疫粒子群优化算法

粒子群优化(PSO)算法^[5]采用信息共享机制,它简单、易实现同时又具有深刻的智能背景的特点。粒子群优化算法的数学抽象和实现步骤如下:

假设在一个 D 维的目标搜索空间中,有 m 个粒子组成一个群落,其中第 i 个粒子表示为一个 D 维向量 $\mathbf{X}_i=(x_{i1}, x_{i2}, \dots, x_{iD}), i=1, 2, \dots, m$,即第 i 个粒子在 D 维搜索空间中的位置是 \mathbf{X}_i 。将 \mathbf{X}_i 带入一个目标函数就可计算出其适应值,根据适应值的大小衡量解的优劣。第 i 个粒子的“飞翔”速度也是一个 D 维的向量,记为 $\mathbf{V}_i=(v_{i1}, v_{i2}, \dots, v_{iD})$ 。记第 i 个粒子迄今为止搜索到的最优位置为 $\mathbf{P}_i=(p_{i1}, p_{i2}, \dots, p_{iD})$,整个粒子群迄今为止搜索到的最优位置为 $\mathbf{P}_g=(p_{g1}, p_{g2}, \dots, p_{gD})$ 。对粒子按下列公式操作

$$\mathbf{V}_i(k+1) = \omega \mathbf{V}_i(k) + c_1 r_1 (\mathbf{P}_i - \mathbf{X}_i(k)) / \Delta t + c_2 r_2 (\mathbf{P}_g - \mathbf{X}_i(k)) / \Delta t \quad (10)$$

$$\mathbf{X}_i(k+1) = \mathbf{X}_i(k) + \mathbf{V}_i(k+1) \Delta t \quad (11)$$

式中: ω 为惯性权重; c_1 和 c_2 为调节 p_{id} 和 p_{gd} 相对重要性的参数; r_1 和 r_2 为区间 $[0, 1]$ 上的随机数; $v_{iD} \in [-v_{max}, v_{max}]$, v_{max} 是常数,由具体问题设定; Δt 是时间间隔,通常取为单位时间。迭代终止条件根据具体问题一般选为最大迭代次数或(和)粒子群迄今为止搜索到的最优位置满足预定最小适应阈值。

在基本的粒子群算法中,随着迭代的进行,越来越多的粒子将接近群体中最好的粒子,而失去它们的速度,变得越来越不活跃。受人工免疫系统的启发,基于免疫系统中发生 T 细胞和 B 细胞中的受体编辑机制,作者提出一种免疫粒子群算法(Immune Particle Swarm Optimization, IPSO)。发生 T 细胞和 B 细胞中的受体编辑是近几年才提出的一种免疫耐受的新机制。受体编辑现象是指 T 细胞和 B 细胞受体在特定的条件下还可以发生新的重排或突变,使其结构发生改变,

从而使其原有的抗原受体特异性向其他特异性漂移或发生亲和力的变化。采用转基因动物模型进行的体内受体编辑实验表明,大约 25% 的 B 细胞发生了受体编辑,受体编辑进一步丰富了抗原受体的多样性^[6]。在免疫粒子群系统中,待解决的问题即是抗原,每一个抗体都代表问题的一个解,同时每个抗体也即是粒子群中的一个粒子。抗原和抗体之间的亲和度由粒子群算法中的适应值来衡量。在免疫粒子群系统中,每隔给定的代数需要鉴别出不活跃的、趋向凋亡的细胞受体,亦即不活跃的粒子,对它们中的 25% 进行受体编辑。

定义

$$\begin{cases} \bar{f} = \frac{1}{n} \sum_{i=1}^n f_i \\ \sigma_f^2 = \frac{1}{n} \sum_{i=1}^n (f_i - \bar{f})^2 \end{cases} \quad (12)$$

式中: f_i 为第 i 个粒子的适应度(第 i 个抗体的亲和度); n 为粒子群规模; \bar{f} 为粒子的平均适应度; σ_f^2 为适应度的方差,反映了群体的收敛程度。

$$\text{定义} \quad \tau^2 = \frac{\sigma_f^2}{\max\{(f_j - \bar{f})^2\}} \quad (13)$$

$$j = 1, 2, \dots, n$$

显然,当 $\sigma_f^2 \neq 0$ 时, $0 < \tau^2 < 1$ 。如果 τ^2 小于一个给定的较小的阈值,同时问题的理论最优解或期望最优解没有达到,这时认为粒子群系统趋于早熟,对系统的趋于凋亡的抗原受体进行受体编辑操作。

$$\text{定义} \quad \frac{f_g - f_j}{\max\{(f_g - f_j)\}} \leq \theta \quad (14)$$

$$j = 1, 2, \dots, n$$

式中: θ 是一个给定的较小的阈值,通常取 $\theta = (f_g - \bar{f}) / 10$; f_g 为最高的抗体亲和度。

本文 τ^2 和 θ 分别取 0.005 和 0.01。对满足不等式(14)的抗原受体 i 进行受体编辑,受体编辑通过对粒子进行一个随机的高斯扰动来完成,按下式实现受体上的基因突变

$$P_{ij} = p_{ij} + \xi_{ij}, j = 1, 2, \dots, D \quad (15)$$

式中: P_{ij} 为抗原 i 的第 j 个基因; ξ_{ij} 服从 $N(0, 1)$ 分布。

3 基于 IPSO 的 Elman 网络学习算法

用 IPSO 算法训练动态 Elman 网络时,定义粒子的位置向量 \mathbf{x} 的元素依次是自反馈增益因子、结构单元的初始输入以及 Elman 网络的全部

连接权。设每个粒子由“头部”和“躯干”两部分组成,头部为自反馈增益因子,躯干为结构单元的初始输入和全部连接权。对图 1 所示的具有 r 个输入节点、 n 个隐层和结构单元节点、 m 个输出层节点的网络,其粒子结构如图 2 所示。

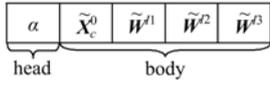


图 2 粒子结构图

Fig. 2 Structure of a particle

图 2 中, $\tilde{X}_c^0 = (x_{c,1}^0, x_{c,2}^0, \dots, x_{c,n}^0)$ 为结构单元初始输入的排列, $\tilde{W}^1, \tilde{W}^2, \tilde{W}^3$ 分别为各权矩阵中元素分别按行展开的一个排列,所以 body 中共有元素 $n + nm + rn + nm$ 个。模拟实验中,权值矩阵的上界和下界分别取为 2 和 -2。在粒子的进化过程中,增加结构发育与结构退化操作实现网络结构的进化。按发育概率 p_b 来决定是否增加隐层的某个神经元,同时增加与之关联的连接权重,新增权重值可根据初始范围随机选择;按退化概率 p_d 来决定是否删除隐层的某个神经元,同时将与之关联的连接权重置为零,而不将其删除,这样可以实现粒子结构的一致。在粒子的每次迭代中,粒子的 body 部分都按式(10)和式(11)进行更新,而 head 部分按自反馈进化概率 p_v 判断自反馈增益因子是否进化,若进化则按式(10)和式(11)进行更新。 p_v, p_d 和 p_b 按下式进行选取

$$p_v = p_d = p_b = e^{-1/NG \cdot \gamma} \quad (16)$$

式中:NG 为自上次出现局部最优解以来至当前代连续未出现更优解的代数; γ 为一个调整系数,可根据具体情况选取,本文取为 0.03。

图 3 为概率随代数的变化曲线,可以看出随着 NG 的增大,网络的结构进化概率增大。

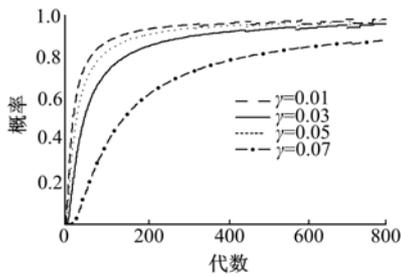


图 3 概率随代数的变化关系

Fig. 3 Relationship between probabilities and generations

4 本文算法对超声马达的辨识

构建了一个基于 IPSO 学习算法的 Elman 网

络非线性系统在线辨识器,以下简称辨识器 IPBEI (IPSO-based Elman identifier)。以超声马达作为一个典型的非线性系统对 IPBEI 的性能进行了检验。

动态辨识器 IPBEI 实现了在线对如图 4 所示的纵向振动超声马达^[7]的速度辨识。马达的参数如下:驱动频率为 27.8 kHz;额定驱动电压为 300 V;额定输出力矩为 0.025 N · m;旋转速度为 3.8 m/s。粒子群规模取为 60,参数 $c_1 = c_2 = 1.0$ 。辨识马达的结构如图 5 所示。

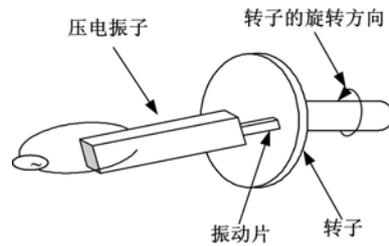


图 4 纵向振动超声马达的示意图

Fig. 4 Schematic diagram of USM

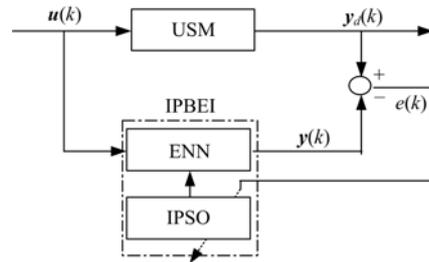


图 5 马达辨识的结构图

Fig. 5 Block diagram of identification model for USM

在模拟实验中 IPSO 在线训练 Elman 网络,免疫粒子群系统中,粒子的适应值利用均方误差进行评价

$$f_j(k) = \frac{1}{E_j(k)} = p / \sum_{i=k-p+1}^k (y_d(i) - y_j(i))^2 \quad (17)$$

式中: $f_j(k)$ 为粒子 j 在 k 时刻的适应度值; p 为辨识窗口宽度,本文取 $p=1$; y_d 为 i 时刻的期望输出; $y_j(i)$ 为粒子 j 对应的 i 时刻网络输出。

在辨识一个采样步后,系统中最后一步产生的粒子群被存贮下来做为下一个采样步的初始群体,只有 20% 的粒子重新进行初始化。因为存贮的粒子很可能已经很接近下一采样步的值,尤其当系统接近或处于稳定阶段的时候。这样每一采样步的辨识都是在上一次辨识的基础上所做的微小调整,可以节省大量的辨识时间,加快在线辨识速度。

采用的样本,即实际马达速度随时间变化的曲线如图 6 所示。为同时考察动态辨识器 IPBEI 的鲁棒性,采用了扰动时间较长的样本数据,扰动时间段为(0.4, 0.7) s。图 6 中曲线 a 表示从开始到稳定阶段的变化情况,曲线 b 是曲线 a 的放大。图 7~图 11 显示了模拟实验的结果。Motor 曲线是指马达的实际速度曲线,Elman 曲线是指采用原始 Elman 网络学习算法即反馈学习算法辨识获得的结果,IPBEI 曲线是指采用本文构建的动态辨识器获得的辨识结果。

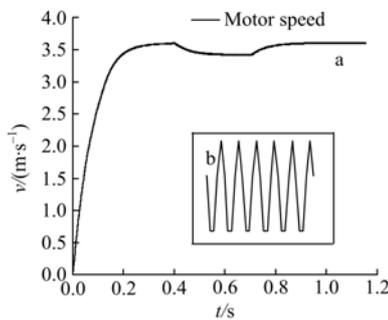


图 6 马达实际速度曲线

Fig. 6 Actual speed curve of USM

图 7 为马达初始阶段的速度辨识结果,使用 IPBEI 辨识结果明显好于反馈算法训练 Elman 网络的辨识结果,最大的辨识误差小于 0.004,明显优于反馈算法训练 Elman 网络的辨识结果的最大误差。图 8 和图 9 分别为扰动阶段和平稳阶段的速度辨识曲线。从这些图中可以明显地看出本文 IPBEI 辨识器对非线性系统进行辨识的优越性。用反馈算法训练 Elman 进行辨识的结果仅能把误差限制在 0.005 内,而每个采样步 IPBEI 辨识器在约 0.3 ms 左右就可以将辨识误差限制在 0.0008 内,辨识误差仅是反馈算法训练辨识误差的 16%左右,辨识精度高于 99.98%。而且每个采样步所需的辨识时间足以满足采样间

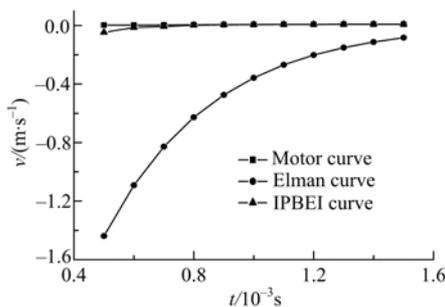


图 7 初始阶段速度辨识曲线

Fig. 7 Speed identification curves at initial stage

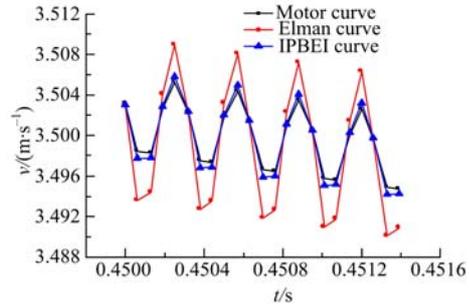


图 8 扰动阶段速度辨识曲线

Fig. 8 Speed identification curves at disturbance stage

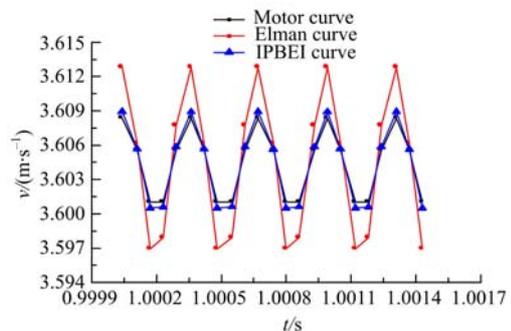


图 9 平稳阶段速度辨识曲线

Fig. 9 Speed identification curves at stabilization stage

隔的要求。模拟结果在 Pentium 4 CPU2.6 GHz、内存 512 MB 的 PC 机上运行,采样数据为 21 000 个,总辨识时间约为 6.2 s。结果表明,作者提出的辨识器 IPBEI 对高度非线性系统的辨识在满足采样间隔的要求下仍可以达到很高的辨识精度,并且当系统遭遇扰动时,IPBEI 能在线学习以适应不确定性,具有很好的鲁棒性。

5 本文算法对超声马达的速度控制

基于 IPSO 学习算法的 Elman 网络构建了一个动态控制器,以下简称 IPBEC (IPSO-based Elman controller),对非线性系统进行控制,仍以上节中提到的超声马达为例进行了性能测试。所提出的控制器适用于任何非线性系统,尤其当系统的模型和工作过程比较复杂时。马达速度控制的结构图如图 10 所示。

在控制器 IPBEC 中,由 IPSO 在线训练 Elman 网络,采用马达的驱动频率作为控制变量。免疫粒子群系统中,粒子的适应值利用控制结果与期望结果的误差进行评价

$$f_j(k) = 1/e_j(k)^2 = 1/(y_d(k) - y_j(k))^2 \tag{18}$$

式中: $f_j(k)$ 为粒子 j 在采样时刻 k 的适应值;

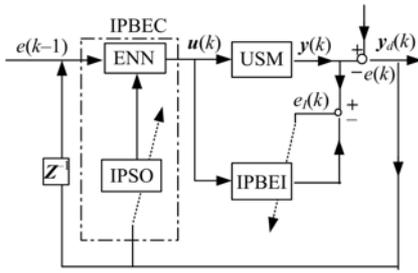


图 10 马达速度控制结构图

Fig. 10 Block diagram of speed control system

$y_d(k)$ 为 k 时刻的期望输出,即参考曲线在 k 时刻的值; $y_j(k)$ 为粒子 j 对应的 k 时刻系统的实际输出。

为了进行实时控制,在每个离散的采样步允许 IPSO 训练 Elman 的时间不能超过采样的时间间隔,对每个采样步本文允许 IPSO 训练 Elman 的时间为 1 ms,等于采样的时间间隔。在控制一个采样步以后,免疫粒子群系统中最后一步产生的粒子群被存储下来做为下一个采样步的初始群体,只有 20% 的粒子重新进行初始化。存储的粒子很可能已经很接近下一采样步的控制变量值,尤其当系统接近或处于稳定阶段的时候。以下的控制结果显示出了 IPBEC 良好的控制性能。

图 11 显示了参考速度曲线为常值 3.6 m/s,外加力矩为 $1 \times 10^{-3} \text{ N} \cdot \text{m}$ 时,采用 3 种不同的控制方案得到的速度控制曲线。其中曲线 a 表示采用文献[8]的方法得到的速度控制曲线,曲线 b 表示采用文献[9]的方法得到的速度控制曲线,曲线 c 表示采用本文提出的 IPBEC 得到的速度控制曲线。定义速度的波动为

$$\zeta = (V_{\max} - V_{\min}) / V_{\text{ave}} \times 100\% \quad (19)$$

式中: V_{\max} 、 V_{\min} 和 V_{ave} 分别表示速度的最大值、最小值和平均值。

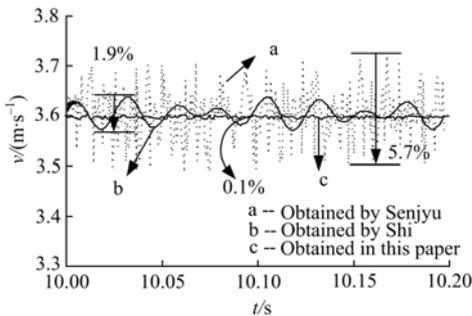


图 11 不同控制方案下马达的速度比较

Fig. 11 Comparison of control curves by different schemes

由图 11 可见,用文献[8]方法得到的速度波动很大,其波动平均值为 5.7%,用文献[8]方法得到的速度波动平均值也较大,其平均值为 1.9%,而用本文方法得到的速度波动相对很小,其平均值仅为 0.1%。

为了进一步验证所提方法对不同参考速度的控制效果,考察了参考速度先按阶梯状变化然后按余弦规律变化的速度控制曲线。图 12 显示了 IPBEC 的速度控制曲线,为了更清晰地观察控制效果,将图 12 的余弦波谷处放大,见图 13。

为了初步测试控制系统的鲁棒性,在参考速度曲线仍采用图 13 中的参考曲线,考察了在控制系统中加入随机瞬态后,系统的响应情况。图 14 显示了在 6 s 时驱动频率有一个随机瞬态扰动的速度响应曲线。从图中可以看出,所

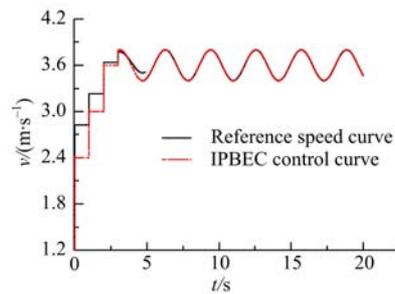


图 12 参考速度随时间变化的速度控制曲线

Fig. 12 Speed control curves with varied reference speeds

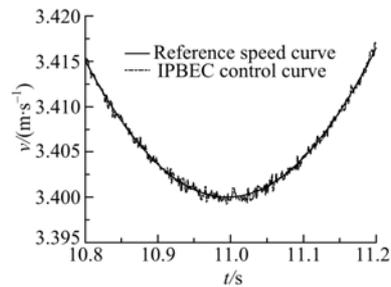


图 13 控制曲线在时间窗(10.8, 11.2) s 内的放大

Fig. 13 An enlargement in time window (10.8, 11.2) s

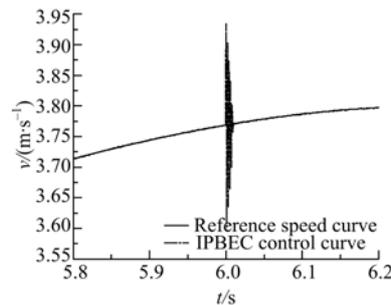


图 14 随机瞬态扰动下的速度响应

Fig. 14 Speed control for randomly disturbance

提出的控制器 IPBEC 对参数变化具有较快的适应能力,这表明系统具有一定的鲁棒性。

6 结束语

采用提出的免疫粒子群优化算法训练动态递归网络,克服了一般的梯度下降法对初始值敏感容易陷入局部极值的弱点,而且不需计算权值的动态导数,降低了算法的计算复杂性,收敛速度不依赖于待辨识和控制系统的维数。所提出的算法对动态递归神经网络的结构、权重、结构单元的初始输入和自反馈增益因子能够实现同时进化学习,保证了算法的合理性,实现了动态递归神经网络的全自动设计。所设计的辨识器 IPBEI 和控制器 IPBEC 能够在线辨识和控制非线性系统。当被辨识和控制对象受噪音扰动导致结构参数发生变化时,能在线自学习,从而适应结构的非线性和不确定性。模拟实验表明,所提出的辨识器和控制器都能达到很高的收敛速度和精度,且具有一定的鲁棒性。

参考文献:

- [1] Hayakawa T, Haddad W M, Hovakimyan N, et al. Neural network adaptive control for nonlinear non-negative dynamical systems[J]. IEEE Transactions on Neural Networks, 2005, 16(2):399-413.
- [2] Xiong Z H, Zhang J. A batch-to-batch iterative optimal control strategy based on recurrent neural network models[J]. Journal of Process Control, 2005, 15(1):11-21.
- [3] 葛宏伟,梁艳春. 进化 Elman 神经网络模型与非线性系统辨识[J]. 吉林大学学报:工学版,2005,35(5):511-519.
- Ge Hong-wei, Liang Yan-chun. Evolutionary Elman neural network model and identification for non-linear systems[J]. Journal of Jilin University(Engineering and Technology Edition), 2005, 35(5):511-519.
- [4] Elman J L. Finding structure in time[J]. Cognitive Science, 1990, 14(2):179-211.
- [5] Kennedy J, Eberhart R. Particle swarm optimization [C]//Proceedings of the IEEE International Conference on Neural Networks, Perth, 1995, 4: 1942-1948.
- [6] Verkozy L K, Martensson A S, Nemazee D. The scope of receptor editing and its association with autoimmunity[J]. Current Opinion in Immunology, 2004, 16(6):808-814.
- [7] Xu X, Liang Y C, Lee H P, et al. Mechanical modeling of a longitudinal oscillation ultrasonic motor and temperature effect analysis[J]. Smart Materials and Structures, 2003, 12(4):514-523.
- [8] Senjyu T, Miyazato H, Yokoda S, et al. Speed control of ultrasonic motors using neural network[J]. IEEE Transactions on Power Electronics, 1998, 13(3): 381-387.
- [9] 时小虎,梁艳春,徐旭. 改进的 Elman 模型与递归反传神经网络[J]. 软件学报, 2003, 14(6):1110-1119.
- Shi Xiao-hu, Liang Yan-chun, Xu Xu. An improved Elman model and recurrent back-propagation control neural networks[J]. Journal of Software, 2003, 14(6):1110-1119.