

基于动态函数连接神经网络的自适应逆控制系统辨识研究

虎涛涛¹ 康波² 单要楠³

(电子科技大学电子科学技术研究院 成都 611731)¹ (电子科技大学自动化工程学院 成都 611731)²
(电子科技大学数学科学学院 成都 611731)³

摘要 自适应逆控制将系统扰动消除和动态响应性能独立分开控制,其性能的优劣取决于系统对象、逆对象及逆控制器模型辨识精度的高低。文中提出用动态函数连接神经网络来实现自适应逆控制系统对象、逆对象的同时在线建模和逆控制器的离线建模,并将模型参数的辨识转化为空间参数寻优。针对混沌初始化对收敛种群结构的破坏性,提出用变参数混沌粒子群优化算法对神经网络权值进行全局寻优,通过仿真实验可以看出基于动态函数连接神经网络的建模误差小,辨识精度高;与当前的参考模型自适应控制方法进行对比分析,所提方法能取得较好的扰动消除效果,并能使系统的跟踪响应性能得到提高,从而验证了方法的有效性、可行性。

关键词 自适应逆控制,扰动消除,系统辨识,动态函数连接神经网络,变参数,混沌粒子群算法

中图分类号 TP183 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2017.10.037

Study on Identification of Adaptive Inverse Control System Based on Dynamic Function Link Neural Network

HU Tao-tao¹ KANG Bo² SHAN Yao-nan³

(Research Institute of Electronic Science and Technology, University of Electronic Science and Technology of China, Chengdu 611731, China)¹
(School of Automation Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China)²
(School of Mathematical Sciences, University of Electronic Science and Technology of China, Chengdu 611731, China)³

Abstract Adaptive inverse control can eliminate the disturbance of the system and control the performance of dynamic response independently, and the performance of the adaptive inverse control system depends on the accuracy of the system object, the inverse object and the controller identification model. In this paper, the dynamic functional link neural network was proposed to realize the simultaneous on-line modeling of the adaptive inverse control system object and inverse object, and realize the off-line modeling of the controller, and the identification of model parameters was transformed into optimization of spatial parameters. Aiming at the destruction of convergent population structure by chaos initialization, this paper presented variable parameter chaotic particle swarm optimization algorithm to optimize the weights of the neural network. Through the simulation experiment, we can see that the modeling error based on the dynamic function link neural network is small and the identification accuracy based on the dynamic function link neural network is high. Compared with the current reference model adaptive control methods, the method in this paper can achieve better disturbance cancellation effect and improve the tracking response performance of the system, thus verifying the effectiveness and feasibility of the method.

Keywords Adaptive inverse control, Disturbance elimination, System identification, Dynamic function link neural network, Variable parameter, Chaos particle swarm optimization algorithm

自适应逆控制^[1] (Adaptive Inverse Control, AIC)由美国斯坦福大学著名教授 B. Widrow 于 1986 年首次命名并提出,它将被控对象的逆模型串联到对象的输入端作为控制器进行开环控制,既能避免因反馈可能引起的系统不稳定现象,又可将系统的动态特性控制和扰动消除控制独立分开,使其互不影响;同时,控制器是自适应的,能最大限度地调节控制器使它们达到最优工作状态,这为控制系统和调节器的设计开辟了新的途径^[2]。AIC 并不限于被控对象是稳定的、最小相

位的,只要保证被控对象是稳定且能控能观的即可,如果被控对象是不稳定的或者非最小相位的,我们可以通过反馈使其稳定,非最小相位问题可在控制系统中通过添加延迟环节来解决。AIC 中的关键组成部分是对象模型、逆对象模型和控制器,尽管其功能和实现方式存在差别,但实质上它们都是一种自适应滤波器^[3-5],自适应逆控制本身要求十分精确的模型解析式,而大多数控制系统通常都呈现出大延迟、大惯性、时变性和不确定性等非线性特征,很难建立精确的数学模型。

来稿日期:2016-09-03 返修日期:2016-11-21

虎涛涛(1990—),男,硕士,主要研究方向为电路与系统、计算机控制系统、控制理论, E-mail: hutao5@126.com;康波(1968—),男,博士,副教授,主要研究方向为计算机控制系统、人工智能、自适应控制;单要楠(1991—),女,硕士,主要研究方向为控制理论。

如果一味地追求精确模型,则会使系统变得异常复杂,即使建立起非线性系统的精确数学模型,也难以推导出逆模型的解析式,因此克服自适应逆控制系统对精确模型的依赖性将是加快逆系统方法变得实用的关键^[6]。神经网络的本质是一种并行结构,它具有任意连续映射的逼近能力以及稳定的动态性能。神经网络的这些特性使得构造一种模型要求低、鲁棒性好、自适应能力强、精度高的自适应逆控制系统成为可能。基于函数连接型神经网络(Functional Link Neural Network, FLNN)的特殊结构和性能^[7],可利用时延关系形成一种动态函数连接型神经网络,从而完成自适应逆控制动态系统的对象模型、逆对象模型及控制器的辨识,辨识的过程可以看作神经网络权值的优化过程;可使用粒子群优化算法来寻优,但粒子群优化算法具有易陷入局部最优解和后期收敛速度慢的缺点,会影响神经网络权值的寻优,进而降低模型的辨识精度,因此本文根据混沌运动所具有的遍历性、随机性、规律性来解决粒子群陷入局部最优、后期收敛速度慢的问题^[8]。针对混沌初始对收敛种群结构的破坏性,可采取适当的规则在算法运行中动态更改混沌控制参数,使种群具有相对稳定的收敛速度,进而保证种群始终以最优的状态寻优全局解。沿着该思路,本文提出了基于变参数混沌粒子群优化算法的动态函数连接型神经网络的自适应逆控制系统辨识方法。

1 自适应逆控制

1.1 自适应逆控制的基本原理

自适应逆控制是一种应用范围非常广泛的新型的先进控制方法,它可以解决其他控制方法无法解决的问题,并且它不必要有逆的存在的特性是其他控制方法都难以企及的^[9]。自适应逆控制中的反馈是局部反馈,仅在自适应迭代过程中调节系统的参数,并不参与控制主回路信号的流动,更没有输出到输入的闭环,因此自适应逆控制是一种开环控制,可利用开环控制的特点进一步改善系统性能。图1是自适应逆控制的基本原理结构图,用对象传递函数的逆作为控制器来驱动对象,并用一种自适应算法调节控制器参数使得对象输出与指令输入的误差最小,在理论上误差为0,上臂传递函数为1,对象输出完全跟随指令输入。




图1 自适应逆控制的基本结构

1.2 参考模型自适应逆控制

经过延迟或平滑的指令输入即为参考模型输入,选取参考模型时应遵循其动态响应与对象期望的动态响应一致,当误差趋于0时,对象便跟踪参考模型,此时上臂控制器与对象串联的传递函数在理论情况下等于参考模型的传递函数,参考模型自适应逆控制结构如图2所示。




图2 参考模型自适应逆控制

1.3 具有扰动消除的参考模型自适应逆控制

在参考模型自适应逆控制^[1]的基础上将已辨识好的对象模型与对象并联,则同一输入作用下的输出之差理论上等于噪声和扰动,用输出之差来驱动逆对象模型以产生过滤后的噪声和扰动,并在对象输入中将其减去(负反馈相减),在逆对象模型理想的情况下,可以将对象扰动和噪声完全消除掉。具有扰动消除的参考模型自适应逆控制结构如图3所示,利用该结构既能消除系统扰动,又能提高系统的动态响应能力。

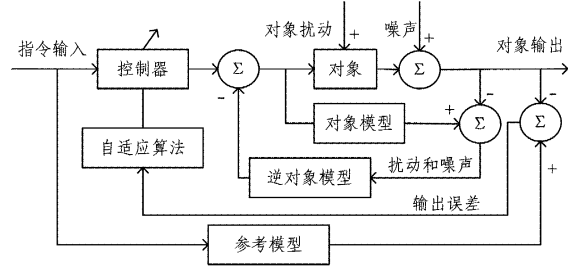


图3 具有扰动消除的参考模型自适应逆控制

2 函数连接型神经网络建模

2.1 动态函数连接型神经网络

FLNN是一种具有全局逼近性能和较强泛化能力的神经网络,它直接对输入模式进行非线性扩展,其作用是将输入模式映射到一个更大的模式空间,从而简化网络结构并提高学习速度^[10-11]。FLNN带有许多与函数连接相关的增加节点,这些节点被用来作为网络的辅助输入,通过权值和阈值的连接形成一个平面网络。为方便讨论,用以下方程来表示一个控制系统。

$$y(k) = -a_1 y(k-1) - \dots - a_n y(k-n) + b_0 u(k) + \dots + b_m u(k-m) + \epsilon(k) \tag{1}$$

$$y(k-1) = -a_1 y(k-2) - \dots - a_n y(k-n-1) + b_0 u(k-1) + \dots + b_m u(k-m-1) + \epsilon(k-1) \tag{2}$$

$$y(k+1) = -a_1 y(k) - \dots - a_n y(k-n+1) + b_0 u(k+1) + \dots + b_m u(k-m+1) + \epsilon(k+1) \tag{3}$$

从上式不难看出, $y(k), y(k-1), \dots$ 都是关于系数 $a_1, a_2, \dots, a_n, b_0, b_1, \dots, b_m$ 的函数,在时域上输入之间相差一个时延,利用输入和输出的关联性可以构造动态FLNN。而系数 $a_1, a_2, \dots, a_n, b_0, b_1, \dots, b_m$ 等同于网络各个节点的权值,通过函数扩展将输入 $u(k)$ 和辨识对象的输出 $y(k)$ 扩展为 $u(k-1), \dots, u(k-m), y(k-1), \dots, y(k-n)$, 并作为FLNN的输入,对其加权求和,最后通过神经元激励函数产生网络输出 $y(k)'$ 。动态函数连接型神经网络结构如图4所示。

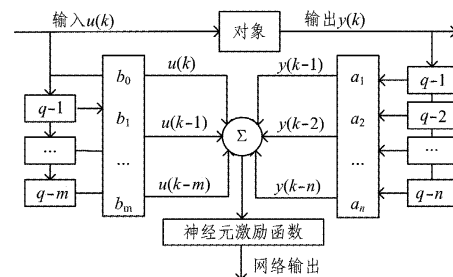


图4 动态函数连接型神经网络

2.2 系统对象和逆对象的在线辨识

本文根据动态 FLNN 的特性提出自适应逆控制系统对象、逆对象的同时在线辨识和控制器的离线辨识。在图 4 的基础上将网络的输出 $y(k)'$ 和实际输出 $y(k)$ 进行比较, 求出输出误差, 该误差信号经过相应的自适应算法不断调整权值, 直至误差趋近于零。而在对象模型辨识的同时将输出 $y(k)$, $y(k-1), \dots, y(k-n)$ 作为另一个神经网络的输入, c_0, c_1, \dots, c_n 为待辨识网络权值, 对其加权求和并经过神经元激励函数产生网络输出 $u(k)'$, 将其与辨识对象输入 $u(k)$ 比较得出输入误差, 再通过对应的自适应算法来调整权值, 直至偏差等于零, 此时网络权值 $a_1', a_2', \dots, a_n', b_0', b_1', \dots, b_m'$ 和 c_0', c_1', \dots, c_n' 分别为对象和逆对象辨识的差分方程系数。其结构如图 5 所示。

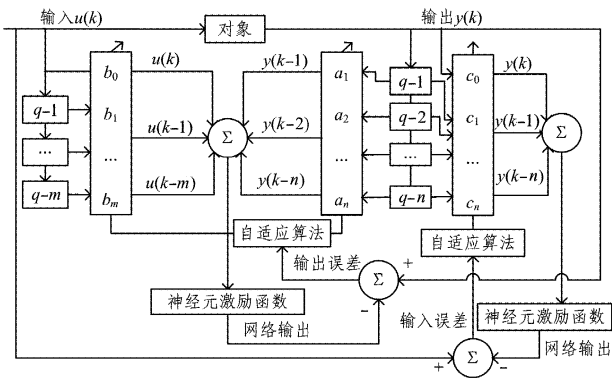


图 5 系统对象、逆对象的在线建模

2.3 系统控制器的离线辨识

针对控制器的辨识, 根据已有的研究成果^[12-13], 由于对象和逆控制器是级联连接的, 采用在线辨识会出现控制器的辨识过程滞后于对象模型的辨识过程的现象, 因此本文采用参考模型逆控制器进行离线辨识, 其结构如图 6 所示。它基于图 5 已辨识好的神经网络, 建模信号同时作用于对象模型和参考模型, 建模信号 $r(k)$ 、对象模型输出 $y(k)$ 以及逆控制器输出 $y_r(k)$ 经函数扩展为 $r(k), \dots, r(k-m)$ 和 $y(k-1), \dots, y(k-n)$ 以及 $y_r(k-1), \dots, y_r(k-n)$, 并作为网络输入, d_1, d_2, \dots, d_n 为待辨识网络权值, 对其加权求和并经过神经元功能函数产生网络输出 $y(k)^*$, 与参考模型输出 $y_m(k)$ 比较得出输出误差, 再通过对对应自适应算法来调整权值, 直至偏差接近于 0, 此时网络权值 d_1', d_2', \dots, d_n' 为参考模型逆控制器的差分方程系数。

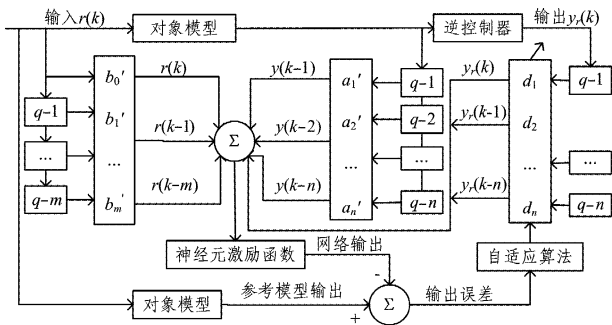


图 6 参考模型逆控制器离线建模

3 变参数混沌粒子群优化算法

上述神经网络建模过程的实质是根据数据样本对神经网络权值进行训练寻优, 因此可将参数辨识问题转换为参数空间上的函数优化问题, 对象以及辨识对象模型用下式表示:

$$y(k) = w_{teo} * x \tag{4}$$

$$y'(k) = w * x \tag{5}$$

$$w_{teo} = (\omega_{1teo}, \omega_{2teo}, \dots, \omega_{nteo}, \omega_{(n+1)teo}, \dots, \omega_{(m+n+1)teo}) \\ = (-a_{1teo}, -a_{2teo}, \dots, -a_{nteo}, b_{0teo}, \dots, b_{nteo}) \tag{6}$$

$$w = (\omega_1, \omega_2, \dots, \omega_n, \omega_{n+1}, \dots, \omega_{m+n+1}) \\ = (-a_1, -a_2, \dots, -a_n, b_0, \dots, b_m) \tag{7}$$

$$x = (x_1, x_2, \dots, x_n, x_{n+1}, \dots, x_{m+n+1}) \\ = (y(k-1), y(k-2), \dots, y(k-n), u(k), \dots, u(k-m)) \tag{8}$$

其中, w_{teo} 为对象参数理论向量, w 为待辨识参数向量, x 是输入向量, 它们共同作用于对象和辨识对象模型; $y(k)$ 是实际对象输出, $y(k)'$ 是辨识网络输出, 为提高参数辨识精度, 选取如下参数寻优目标函数:

$$f = \frac{1}{N} \sum_{k=1}^N (y(k) - y'(k))^2 \tag{9}$$

自适应算法通过 $y(k)$ 和 $y'(k)$ 输出之差不断调整待辨识参数向量 w 直至误差减小到最小甚至为 0, 为 0 时待辨识参数向量 w 等于对象参数理论向量 w_{teo} , 即完成对象模型的辨识, 这一过程即对寻优目标函数 f 求最小值, 因此选取性能较好的寻优算法至关重要, 逆对象、控制器的辨识原理与此相同。

粒子群优化算法是一种群智能的全局优化进化算法, 该算法的机理是对群体中每一个粒子赋予位置和速度两个特性, 每个粒子的优劣由目标函数作为适应度来衡量, 粒子通过位置和速度这两个特性的极值来更新自己的空间位置解, 经过多次迭代直至找到最优解。算法的数学描述为: 粒子种群规模为 N , 搜索空间维数为 D , 则 $x_i = (x_{i1}, \dots, x_{id}, \dots, x_{iD})$ 和 $v_i = (v_{i1}, \dots, v_{id}, \dots, v_{iD})$ 分别是第 i 个粒子的当前搜索位置和飞行速度; x_{id} 和 v_{id} 分别是第 i 个粒子的第 d 维空间位置和飞行速度, 适应度函数为 $f(x)$, 即寻优目标函数 f ; $p_i = (p_{i1}, \dots, p_{id}, \dots, p_{iD})$ 是个体最优解, $p_g = (p_{g1}, \dots, p_{gd}, \dots, p_{gD})$ 是全局最优解, 并且只有一个 p_g 。设当前迭代次数为 k , 则有:

$$v_{id}^{k+1} = \alpha * v_{id}^k + c_1 rand_1 (p_{id}^k - x_{id}^k) + c_2 * rand_2 (p_{gd}^k - x_{id}^k) \tag{10}$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \tag{11}$$

粒子在每一次迭代中找到上述两个最优解后, 根据式 (10) 和式 (11) 来更新速度 v_i 和位置 x_i , 并按照下式更新 p_i 和 p_g :

$$p_i^{k+1} = \begin{cases} p_i^k, & f(x_i^{k+1}) \geq f(p_i^k) \\ x_i^{k+1}, & f(x_i^{k+1}) < f(p_i^k) \end{cases} \tag{12}$$

$$p_g^k = \min\{f(p_1^k), f(p_2^k), \dots, f(p_n^k)\} \tag{13}$$

其中, $i=1, \dots, N; d=1, \dots, D, \alpha$ 是用于修正自身飞行速度的惯性因子, $c_1, c_2, rand_1, rand_2$ 为常数。

粒子群优化算法因简单易实现、调整参数少等优点得到

了快速发展,但易陷入局部最优、收敛精度低是其存在的主要问题,研究学者为解决这些问题提出了许多改进算法,如混合粒子群算法^[14]、混沌粒子群算法^[15]。混沌运动的随机性、遍历性、规律性可以很好地解决基本粒子群中的瓶颈问题,有助于提高算法的全局收敛性能,但在种群陷入局部最优时,混沌初始化会破坏已收敛种群的结构。为解决这一问题,本文从混沌系统本身着手研究。Logistic方程是一个典型的混沌系统,可表示为:

$$z_{n+1} = \mu * z_n * (1 - z_n), n=0, 1, 2, \dots \quad (14)$$

其中, μ 为混沌控制参数,决定 Logistic 方程的混沌程度。 μ 值越大,混沌程度越高,对种群结构的破坏性就越大,因此可以在算法运行过程中根据种群的收敛情况,动态减小或增大控制参数 μ ,这既可以避免对种群结构的破坏,又能充分利用混沌特性来摆脱局部最优的困境,提高算法的全局优化能力。基于这一思想,本文提出变参数混沌粒子群优化算法。该算法利用群体适应度方差进行早熟收敛判断,当发现种群陷入局部最优时,保留粒子群个体最优解,并混沌初始化粒子群,根据一定的规则动态增大或减小混沌控制参数 μ ,避免混沌初始化对已收敛种群结构的破坏,从而在保证收敛速度的基础上既摆脱了种群陷入局部最优的现象,又能提高收敛精度和全局优化能力。变参数混沌粒子群优化算法的具体描述如下。

1) 初始化参数:种群规模 N ,粒子搜索空间维数 D ,学习因子 c_1 和 c_2 ,惯性因子 α 的最大值和最小值,混沌控制参数 u ,迭代次数 T 。

2) 混沌初始化种群:随机产生一组取值区间为 $[0, 1]$ 的变量 $z_1 = (z_{11}, \dots, z_{1d}, \dots, z_{1D})$,利用 Logistic 方程产生 $N-1$ 个混沌变量 z_2, \dots, z_N ,并根据 $x_i = x_{\min} + (x_{\max} - x_{\min}) * z_i$ 将 N 个变量映射到粒子位置取值区间 $[x_{\min}, x_{\max}]$ 上,以生成位置变量和速度变量;选取合适的适应度函数 $f(w)$,本文中为参数寻优目标函数 f ,并求出初始种群的个体最优解 p_i 和全局最优解 p_g 。

3) 根据式(10)和式(11)来更新粒子位置 x_i 和速度 v_i 。

4) 根据 $f(w)$ 求出粒子的适应度,并根据式(12)和式(13)来更新个体最优解 p_i 和全局最优解 p_g 。

5) 选取适应度方差规则并计算群体适应度方差 $\sigma^2 = \sum_{i=1}^N [(f_i - \bar{f}) / f_0]^2$, f_i 是第 i 个粒子的适应度, \bar{f} 是当前粒子群的平均适应度, f_0 是归一化因子。如果 f_i 和 \bar{f} 之差的绝对值的最大值大于或等于 1,则 f_0 取最大值;否则 f_0 取值为 1。如果 σ^2 小于设定的阈值且满足混沌搜索条件,则根据准则判断粒子群收敛情况,保留粒子群个体最优解 p_i ,动态改变混沌控制参数 u ,返回步骤 2) 对种群混沌初始化,根据 $f(w)$ 求出粒子的适应度,并与保留的粒子群个体的最优解进行比较,求出 p_g 。

6) 判断是否满足终止条件或达到最大迭代次数 T ,满足则转到步骤 7),否则返回步骤 3)。

7) 优化结束,输出结果,此时最优解 p_g 即为待辨识参数向量。

4 基于函数连接神经网络的自适应逆控制的稳定性

在控制系统的设计中,李雅普诺夫第二法是比较有效的分析系统稳定性和收敛性的方法^[16],其核心思想是构造一个李雅普诺夫函数,并要求该函数是正定的且一阶导数是负定的。对神经网络算法的收敛性分析,一般从神经网络权向量的收敛性和输出误差的收敛性进行。根据图 5 和图 6 的结构,通过分析输出误差的收敛性来确定神经网络自适应逆控制的稳定性。为方便叙述,设 y_k 和 \hat{y}_k 分别为系统的期望输出和网络输出,选取的李雅普诺夫函数如下:

$$V_k = \frac{1}{2} e_k^2 = \frac{1}{2} (y_k - \hat{y}_k)^2 \quad (15)$$

$$\Delta V_k = V_{k+1} - V_k = \frac{1}{2} (e_{k+1}^2 - e_k^2) \quad (16)$$

假定期望输出 y_k 不变, $f(x)$ 为神经元激励函数,要求神经网络输出 \hat{y}_k 跟踪 y_k ,则有:

$$\begin{aligned} \Delta e_k &= e_{k+1} - e_k = (y_k - \hat{y}_{k+1}) - (y_k - \hat{y}_k) \\ &= \hat{y}_k - \hat{y}_{k+1} = f(w_k^T x_k) - f(w_{k+1}^T x_k) \\ &= -(f(w_k^T x_k + \Delta w_k^T x_k) - f(w_k^T x_k)) \\ &\approx -(\partial f(x) / \partial x |_{x=w_k^T x_k} * \Delta w_k^T x_k) \\ &= f'(w_k^T x_k) * \Delta w_k^T x_k \end{aligned} \quad (17)$$

利用 Taylor 级数展开式并忽略二阶及其以上高阶来近似函数 $f(x)$,令 $u_k = w_k^T x_k$, η 为神经网络学习率,则网络权值的修正量可以表示为:

$$\Delta w_k = -\eta f'(u_k) e_k x_k^T \quad (18)$$

将其代入式(17),可得:

$$\Delta e_k \approx -\eta [f'(u_k)]^2 e_k x_k^T x_k \quad (19)$$

$$\begin{aligned} \Delta V_k &= \frac{1}{2} (2e_k \Delta e_k + \Delta e_k^2) \\ &= \Delta e_k (e_k + \frac{1}{2} \Delta e_k) \\ &= -\eta [f'(u_k)]^2 e_k \|x_k\|^2 (e_k - \frac{1}{2} \eta [f'(u_k)]^2 e_k \|x_k\|^2) \\ &= \eta [f'(u_k)]^2 e_k^2 \|x_k\|^2 (1 - \frac{1}{2} \eta [f'(u_k)]^2 e_k \|x_k\|^2) \end{aligned} \quad (20)$$

因此,要使网络学习过程收敛和稳定, ΔV_k 必须为负定的,即在 $\Delta V_k < 0$ 的情况下,学习率 η 应满足:

$$0 < \eta < \frac{2}{[f'(u_k)]^2 e_k \|x_k\|^2} \quad (21)$$

5 实验验证

为验证方法的可行性和有效性,选取稳定平台作为自适应逆控制的控制对象,并进行对象、逆对象及控制器的建模。文献[13]提供的稳定平台的传递函数如下:

$$\begin{aligned} G(s) &= \frac{1.923}{0.000133s^2 + 0.0338s + 1} \\ &= \frac{25575.9}{s^2 + 449.54s + 13300} \end{aligned} \quad (22)$$

采样时间选取 0.01,对 $G(s)$ 进行离散化,并按照图 5 所示的结构进行对象及逆对象的在线建模。通过离散化 $G(s)$ 可以得出对象参数向量的理论值 $w_{no}=(0.7426,-0.01116,0.4114,0.1049)$,待辨识对象参数向量为 $w=(a_1,a_2,b_1,b_2)$,建模输入信号 $u(z)$ 为方差为 1 的白噪声序列。参考模型选取:

$$G_m(s)=\frac{511.52}{s^2+32.84s+31.84} \quad (23)$$

采样时间选取 0.01,对 $G_m(s)$ 进行离散化,将已辨识好的对象模型复制到图 6 中,并按照图 6 所示的结构进行控制器离线建模,此时对象模型的输入输出可用式(24)表示:

$$y(z)=a_1'y(z-1)+a_2'y(z-2)+b_1'r(z-1)+b_2'r(z-2) \quad (24)$$

$w'=(a_1',a_2',b_1',b_2')$ 是已辨识好的对象模型参数向量,参考模型逆控制器可表示为:

$$\begin{aligned} y_r(z) &= c_1 y_r(z-1) + c_2 y(z) + c_3 y(z-1) \\ &= c_1 y_r(z-1) + (c_2 \times a_1' + c_3) y(z-1) + c_2 \times \\ &\quad a_2' y(z-2) + c_2 \times b_1' r(z-1) + c_2 \times b_2' r(z-2) \end{aligned} \quad (25)$$

为方便讨论,参考模型逆控制器可表示为:

$$y_{no}(z)=d_1 y_r(z-1)+d_2 y(z-1)+d_3 y(z-2)+d_4 r(z-1)+d_5 r(z-2) \quad (26)$$

$w_e=(d_1,d_2,d_3,d_4,d_5)$ 为参考模型逆控制器待辨识参数向量,其理论值可以根据 $G_m(s)$ 和 $G(s)$ 求得,依次为 0.99, 0.077972, -0.000223, 0.008228, 0.002098。建模输入信号 $r(z)$ 为方差为 1 的白噪声序列。

变参数混沌粒子群优化算法的初始化参数如下:种群规模 N 为 20,对象辨识算法中粒子维数 D 为 4,逆对象辨识为 3,参考模型逆控制器辨识为 5,位置 x_i 和速度 v_i 的取值范围设置为 $[-2,2]$,学习因子 c_1 和 c_2 都为 2,惯性因子 α 的最大值为 1,最小值为 0.2,混沌控制参数 u 为 4,迭代次数 T 为 1000。各算法独立运行 50 次,所有参数辨识值取平均值,表 1 列出了待辨识对象参数 a_1, a_2, b_1, b_2 和参考模型逆控制器待辨识参数 d_1, d_2, d_3, d_4, d_5 的辨识结果。

表 1 辨识参数优化计算结果

参数	理论值	辨识值	误差
a_1	0.742600	0.738054	0.004546
a_2	-0.011160	-0.012151	0.000991
b_1	0.411400	0.415662	0.004262
b_2	0.104900	0.106118	0.001218
d_1	0.990000	0.990511	0.000511
d_2	0.077972	0.078122	0.000150
d_3	-0.000223	-0.000189	0.000034
d_4	0.008228	0.008186	0.000042
d_5	0.002098	0.001895	0.000203

根据参考模型逆控制器的表达式 $y_r(z)$ 和 $y_{no}(z)$ 可知,逆控制器待辨识参数 c_1, c_2, c_3 的理论值可按 $c_1=d_1, c_2=d_3/a_2, c_3=d_2-c_2 \times a_1$ 来计算,同理可计算辨识值。根据表 1 的实验数据计算辨识值,结果如表 2 所列。

表 2 辨识参数优化计算结果

参数	理论值	辨识值	误差
c_1	0.990000	0.990511	0.000511
c_2	0.019982	0.015554	0.004428
c_3	0.063133	0.066642	0.003509

由表 1 和表 2 的实验数据可知,待辨识参数的辨识误差非常小,最大误差精确到 0.001,而最小误差能达到 0.00001,辨识精度较高,足以满足系统要求。对象辨识参数及逆对象辨识的参数误差曲线如图 7 所示,参考模型逆控制器辨识参数的轨迹曲线如图 8 所示。




图 7 对象辨识参数及逆对象辨识参数的误差曲线




图 8 参考模型逆控制器辨识参数的轨迹曲线

从图 7 可以看出,逆对象辨识参数误差随着迭代次数的增加逐渐减小,迭代次数约为 700 时基本接近于零,与此对应的对象辨识参数也达到收敛精度。从图 8 可以看出,逆控制器的辨识轨迹曲线也在 700 次左右收敛,因此,对象和逆对象基于动态 FLNN 的辨识方法是有效可行的,且有较高的辨识精度。将辨识好的对象模型、逆对象模型及参考模型逆控制器按照图 3 所示的结构来实现参考模型自适应逆控制的扰动消除,用幅值为 10 的方波作为指令输入,用方差为 1 的白噪声作为系统扰动。为了体现本文所提方法的优越性,用模型参考自适应控制^[17]来控制稳定平台进行对比实验,其中模型参考自适应律选择 MIT。在相同输入信号作用下的系统跟踪响应曲线如图 9 所示。




图 9 系统跟踪响应曲线

图9所示的结构中, $y_m(k)$ 是参考模型的输出, $y_p(k)$ 是自适应律为MIT的模型参考自适应控制的系统输出, $y(k)$ 是文中的参考模型AIC的系统输出,它们都能很好地跟踪参考模型输出 $y_m(k)$, 具有较快的响应速度;而参考模型AIC的跟踪误差较小,说明了基于动态FLNN辨识的自适应逆控制系统对象、逆对象和控制器的有效性和可行性。按照图3的结构,在参考模型AIC的基础上添加扰动消除机制,其系统跟踪响应曲线如图10所示。




图10 具有扰动消除的系统跟踪响应曲线

从图10可以明显看出,具有扰动消除机制的参考模型AIC系统的噪声和扰动基本被消除,并能以极其小的误差跟踪参考模型的输出,说明对象、逆对象的模型辨识精度较高,从而使对象和对象模型之差几乎等同于噪声扰动;而自适应律为MIT的模型参考自适应控制没有这种消除机制,因此跟踪效果较差,性能较低。

结束语 自适应逆控制的性能取决于对象、逆对象和逆控制器辨识精度的高低,文中用时延关联性构造动态函数连接神经网络,并用该网络进行对象和逆对象的在线建模以及参考模型逆控制器的离线建模,从而解决了静态函数连接神经网络对动态系统不适用的问题;同时提出了自适应逆控制的对象和逆对象同时在线建模的动态函数连接神经网络结构,将网络参数 μ 的辨识转化为空间参数寻优,用粒子群算法进行网络权值的全局寻优。针对混沌粒子群优化算法中混沌运动对已收敛种群结构的破坏性,提出了变参数混沌粒子群优化算法,在算法迭过程中动态改变混沌控制参数 μ 的大小,一方面可避免混沌初始化对已收敛种群结构的破坏,另一方面可以保证以最佳混沌状态寻优全局最优值。最后通过仿真对比实验说明用动态函数连接神经网络辨识的对象、逆对象及逆控制器的精度较高,并达到了很好的扰动消除效果,极大地提高了系统的动态跟踪性能。

参考文献

[1] WIDROW B, WALACH E. 自适应逆控制[M]. 刘绍棠, 韩崇昭, 译. 西安: 西安交通大学出版社, 2000.

[2] 卢志刚, 吴士昌, 于灵慧. 非线性自适应逆控制及其应用[M]. 北京: 国防工业出版社, 2004.

[3] COCHOFEL H J, WOOTEN D, PRINCIPE J. A neural network development environment for adaptive inverse control [J]. IEEE World Congress on Computational Intelligence, 1998, 2: 963-967.

[4] FAUSZ J L, CHELLABOINA V S, HADDAD M M. Inverse op-

timial adaptive control for nonlinear uncertain systems with exogenous disturbances [C] // Proceedings of the 36th Conference on Decision and Control, 1998: 2654-2659.

[5] XIE S Y. Adaptive inverse control and its application [D]. Shandong: Shandong University, 2007. (in Chinese)
解淑英. 自适应逆控制及其应用研究[D]. 山东: 山东大学, 2007.

[6] LIU S, YU J S. Composite control combining neuro-fuzzy inverse control with pid control and its application in a continuous stirred tank reactor [J]. Control Theory and Applications, 2001, 18(5): 769-773.

[7] MIREA, LETITIA. System identification using functional-link neural networks with dynamic structure [C] // 15th Triennial World Congress, Barcelona, Spain, 2002.

[8] LU H J. A new optimization algorithm based on Chaos [J]. Zhejiang University Science A, 2006, 7(4): 539-542.

[9] HAN H. The study of adaptive inverse control algorithm based on LMS [D]. Changsha: Central South University, 2008. (in Chinese)
韩华. 基于LMS算法的自适应逆控制方法研究[D]. 长沙: 中南大学, 2008.

[10] LIU T, HAN H T, MA J. Study on model identification of Hammerstein sensor based on the function link neural network [J]. Acta Metrologica Sinica, 2015, 36(1): 97-101. (in Chinese)
刘滔, 韩华亭, 马婧. 基于函数连接神经网络的传感器 Hammerstein 模型辨识研究[J]. 计量学报, 2015, 36(1): 97-101.

[11] GUO Q M, HU H. The On-Line Monitoring System of Tower Crane Load Based on FLNN [J]. Advanced Materials Research, 2012, 466-467: 1373-1377.

[12] GONG Y L. The research of adaptive inverse control strategy for permanent magnet synchronous motor servo system [D]. Changchun: Changchun University of Science and Technology, 2013. (in Chinese)
宫玉琳. 永磁同步电动机伺服系统自适应逆控制策略研究[D]. 长春: 长春理工大学, 2013.

[13] BAI Y. Research on high precision stabilized platform based on adaptive inverse control [D]. Harbin: Harbin Institute of Technology, 2012. (in Chinese)
白杨. 基于自适应逆控制的高精度稳定平台的研究[D]. 哈尔滨: 哈尔滨工业大学, 2012.

[14] LI J W, CHENG Y M, CHEN K Z. Chaotic particle swarm optimization algorithm based on adaptive inertia weight [C] // Control and Decision Conference, Beijing: IEEE, 2014: 1310-1315.

[15] PAN T S, DAO T K, CHU S C. Hybrid particle swarm optimization with bat algorithm [M]. Switzerland: Springer International Publishing, 2015: 37-47.

[16] 胡寿松. 自动控制原理[M]. 北京: 科学出版社, 2013

[17] LI J, QI X H, LIU X H, et al. Improved model reference adaptive control and its application in decoupling control [J]. Journal of Electrical and Control, 2015, 19(5): 112-120. (in Chinese)
李杰, 齐晓慧, 刘新海, 等. 改进模型参考自适应控制及其在解耦控制中的应用[J]. 电机与控制学报, 2015, 19(5): 112-120.