

文章编号: 1001-0920(2008)08-0938-06

改进的非线性鲁棒自适应动态面控制

周 丽, 姜长生

(南京航空航天大学 自动化学院, 南京 210016)

摘 要: 针对不确定多输入多输出严格反馈块非线性系统, 提出一种鲁棒自适应动态面控制方法. 该方法在反推自适应神经网络控制中引入动态面控制简化控制律, 同时对自适应律进行改进以改善系统的过渡过程动态品质, 保证了系统在简化的控制律下仍具有良好的动态特性. 通过 Lyapunov 方法证明了闭环系统所有信号均有界, 系统的跟踪误差指数收敛到有界紧集内. 最后给出的某新型战斗机六自由度仿真结果表明了该方法的有效性.

关键词: 鲁棒自适应控制; 动态面控制; RBF 神经网络; 多输入多输出; 新型战斗机

中图分类号: TP273

文献标识码: A

Improved robust and adaptive dynamic surface control for nonlinear systems

ZHOU Li, JIANG Chang-sheng

(College of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China.

Correspondent: ZHOU Li, E-mail: lk_zhouli@163.com)

Abstract: A robust and adaptive dynamic surface control approach is presented for uncertain MIMO nonlinear systems with block-strict-feedback form. By incorporating dynamic surface control technique into the design framework of backstepping methodology combining with adaptive neural networks, the problem of "explosion of complexity" inherent in the existing method is eliminated and the complexity of control law is reduced. In addition, adaptive tuning rules of parameters are improved to achieve good transient behaviour. The approach ensures that with simplified control law, the system still possesses good dynamic characteristics. Furthermore, the closed-loop signals are guaranteed to be bounded and output tracking error are proved to converge exponentially to a small compact by Lyapunov approach. Finally, nonlinear six-degree-of-freedom (6 DOF) numerical simulation results for the new generation fighter demonstrate the effectiveness of the approach proposed.

Key words: Robust and adaptive control; Dynamic surface control; RBFNN; MIMO; New generation fighter

1 引 言

反推法是非线性控制系统设计中广泛使用的一种方法. 将神经网络、模糊系统等与反推法结合, 可以解决一大类不确定非线性系统的鲁棒自适应控制器设计问题^[1-3]. 由于反推法的快速收敛特性及良好的鲁棒性, 已在航空航天领域获得了广泛的研究^[4-6]. 然而计算膨胀问题是反推法的一大缺陷, 由于每一步递推设计中都要对虚拟控制律进行重复求导, 导致虚拟控制量所含项随系统阶数的增加以指数形式增长^[7], 使得控制律变得高度非线性、高度复杂. 当反推控制器应用于导弹、飞机等多变量非线性系统时, 其计算量往往是机载计算机难以承受的. 因

此, 研究如何减少控制律的复杂程度的同时不降低其过渡过程品质, 已成为反推自适应控制方法急待解决的问题^[8].

针对反推法的计算膨胀问题, 文献[9]首次提出了动态面控制(DSC)方法. 文献[10, 11]分别对单输入单输出及块三角不确定非线性系统进行了自适应神经网络动态面控制研究. 针对不确定严格反馈块非线性系统, 文献[7]利用非线性跟踪微分器来解决反推自适应神经网络控制器的计算膨胀问题, 但文中为了保证神经网络权值估计有界引入了投影算子, 使自适应律变得复杂.

本文在文献[7]的基础上, 研究了控制增益矩阵

收稿日期: 2007-05-31; 修回日期: 2007-09-10.

基金项目: 国家自然科学基金项目(90405011).

作者简介: 周丽(1976—), 女, 山东烟台人, 博士生, 从事智能控制、非线性鲁棒自适应控制的研究; 姜长生(1942—), 男, 南京人, 教授, 博士生导师, 从事智能控制、非线性鲁棒控制等研究.

未知的严格反馈块控非线性系统的鲁棒自适应动态面控制方法. 系统的不确定性及外界干扰由 RBF 神经网络在线逼近, 在现有的反推自适应神经网络控制器中引入动态面控制技术降低控制的复杂性, 同时对参数自适应律进行改进, 使之可以动态调节神经网络收敛速度, 改善系统过渡过程的动态品质. 利用 Lyapunov 方法证明了闭环系统的稳定性.

2 问题描述

考虑如下 MIMO 严格反馈块控非线性系统:

$$\begin{cases} \dot{x}_i = f_i(\bar{x}_i) + g_i(\bar{x}_i) x_{i+1} + d_i, & 1 \leq i < n, \\ \dot{x}_n = f_n(\bar{x}_n) + g_n(\bar{x}_n) u + d_n, \\ y = x_1. \end{cases} \quad (1)$$

其中: $\bar{x}_n = [x_1^T, x_2^T, \dots, x_n^T]^T$ 为状态向量; $\bar{x}_i = [x_i^T, x_{i+1}^T, \dots, x_n^T]^T$, $x_i \in R^{m_i}$, m_i 为子系统的阶次; $u = [u_1, u_2, \dots, u_{m_n}]^T$ 为控制输入向量; y 为系统输出; $f_i(\bar{x}_i)$, $g_i(\bar{x}_i)$ 为相应维数的光滑向量或矩阵函数; d_i 为参数不确定性及未知外界干扰, 可表示为

$$\begin{cases} d_i = f_i(\bar{x}_i) + g_i(\bar{x}_i) x_{i+1} + d_i, & 1 \leq i < n, \\ d_n = f_n(\bar{x}_n) + g_n(\bar{x}_n) u + d_n, \end{cases} \quad (2)$$

d_i 为未知外界干扰, 满足 $d_i \in D(\bar{x}_i, t)$, $D(\bar{x}_i, t)$ 为 C^1 上的光滑有界函数, $\|\cdot\|$ 表示向量的 Euclid 范数或矩阵的 Frobenius 范数.

控制系统的目标是消除不确定和干扰对系统的影响, 稳定跟踪给定的输入参考信号 $y_r(t)$, $t \geq 0$.

本文使用文献[1]中的 RBF 神经网络来逼近系统的不确定性和干扰. RBFNN 收敛速度快, 能够以任意精度逼近任意光滑非线性函数. 给定一个光滑的函数向量 $F: R^n \rightarrow R^p$, 则存在一个 RBF 基函数向量 $\phi: R^m \rightarrow R^p$, 及理想权值矩阵 $W^* \in R^{p \times m}$, 使得

$$F(x) = W^{*T} \phi(x) + \epsilon. \quad (3)$$

其中: Ω 为 R^m 上的紧集; Ω 为神经网络的逼近误差, ϵ_H, ϵ_H 为常数; 理想权值矩阵 W^* 取为在紧集 Ω 内使得 ϵ 最小的 W^* , 定义为

$$W^* = \arg \min_W \left\{ \sup_{x \in \Omega} \|F(x) - W^T \phi(x)\| \right\}. \quad (4)$$

3 改进的动态面控制器设计及稳定性分析

3.1 控制器设计

控制器的递推设计包括 n 步, 为了方便起见, 以下将 $f_i(\bar{x}_i)$ 和 $g_i(\bar{x}_i)$ 分别简写为 f_i 和 g_i . 下面首先给出系统设计需满足的假设条件:

假设 1 g_i 有界, 即存在常数 $g_{i1} \leq g_i \leq g_{i0} > 0$, 使得 $g_{i0} \leq g_i \leq g_{i1}$.

假设 2 g_i 可逆.

注 1 当 g_i 不是方阵时不存在逆矩阵, 只存在广义逆, 这时文中 g_i^{-1} 表示最小二乘广义逆.

假设 3 神经网络理想权值矩阵 W^* ($i = 1, 2, \dots, n$) 有界, 即 $W^* \in \mathcal{M}_i, \mathcal{M}_i$ 为系统的设计参数.

Step 1 考虑闭环系统(1)的第 1 个子系统

$$\dot{x}_1 = f_1 + g_1 x_2 + d_1, \quad (5)$$

定义误差状态向量 $S_1 = x_1 - x_{1d}$, 对其求导得

$$\dot{S}_1 = f_1 + g_1 x_2 + d_1 - \dot{x}_{1d}. \quad (6)$$

其中: $x_{1d} = y_r$ 为系统的参考输入, 因 \dot{y}_r 未知, 在此用神经网络逼近, 则式(6)可表示为

$$\dot{S}_1 = f_1 + g_1 x_2 + \hat{W}_1^T \phi_1 + d_1 - \dot{x}_{1d}. \quad (7)$$

子系统 1 的虚拟控制律及自适应律选取如下:

$$\begin{cases} \bar{x}_2 = g_1^{-1} [-k_1 S_1 - f_1 - \hat{W}_1^T \phi_1 + \dot{x}_{1d}], \\ \dot{\hat{W}}_1 = -\gamma_1^{-1} S_1^T \phi_1 - \hat{W}_1. \end{cases} \quad (8)$$

其中: $k_1 > 0$ 为常数; \hat{W}_1 为 W_1^* 的估计值, $\tilde{W}_1 = W_1^* - \hat{W}_1$ 为神经网络的权值估计误差; $\gamma_1 = \text{diag}[\gamma_{1j}] > 0$ 为常数矩阵; $\gamma_1 = \text{diag}[\gamma_{1j}] > 0$; $\gamma_{1j} > 0$ 为常数; $j = 1, 2, \dots, l_1$, l_1 为神经网络的隐层单元数.

受文献[9]的启发, 将 \bar{x}_2 通过时间常数为 τ_2 的一阶低通滤波器得到其估计值 z_2 , 即

$$\tau_2 \dot{z}_2 + z_2 = \bar{x}_2, \quad z_2(0) = \bar{x}_2(0). \quad (9)$$

这样, 在下一步设计中无需对 \bar{x}_2 中的非线性项进行求导, 从而避免了反推法的计算膨胀问题, 简化了控制律.

Step i 考虑系统(1)的第 i 个子系统

$$\dot{x}_i = f_i + g_i x_{i+1} + d_i, \quad 2 \leq i \leq n-1, \quad (10)$$

定义误差向量 $S_i = x_i - z_i$, 对其求导得

$$\dot{S}_i = f_i + g_i x_{i+1} + d_i - \dot{z}_i. \quad (11)$$

子系统 i 的虚拟控制律及自适应律选取如下:

$$\begin{cases} \bar{x}_{i+1} = g_i^{-1} [-k_i S_i - f_i - \hat{W}_i^T \phi_i - g_{i-1}^T S_{i-1} + \dot{z}_i], \\ \dot{\hat{W}}_i = -\gamma_i^{-1} S_i^T \phi_i - \hat{W}_i, \end{cases} \quad (12)$$

其中 $k_i, \hat{W}_i, \gamma_i, \gamma_i$ 及 γ_i 的定义同 Step 1 类似. 将 \bar{x}_{i+1} 通过时间常数为 τ_{i+1} 的一阶低通滤波器, 得到 \bar{x}_{i+1} 的估计值 z_{i+1} , 即

$$\tau_{i+1} \dot{z}_{i+1} + z_{i+1} = \bar{x}_{i+1}, \quad z_{i+1}(0) = \bar{x}_{i+1}(0). \quad (13)$$

Step n 考虑系统(1)的第 n 个子系统

$$\dot{x}_n = f_n + g_n u + d_n, \quad (14)$$

定义误差状态向量 $S_n = x_n - z_n$, 对其求导得

$$\dot{S}_n = f_n + g_n u + d_n - \dot{z}_n. \quad (15)$$

令闭环系统的控制输入及自适应律分别为

$$\begin{cases} u = g_n^{-1} [-k_n S_n - f_n - \hat{W}_n^T \phi_n - g_{n-1}^T S_{n-1} + \dot{z}_n], \\ \dot{\hat{W}}_n = -\gamma_n^{-1} S_n^T \phi_n - \hat{W}_n, \end{cases} \quad (16)$$

其中 k_n, \hat{n}, n^*, n, n 及 n 的定义同 Step1 类似.

动态面控制虽然降低了反推自适应控制器的复杂性,但容易引起过渡过程振荡^[10,11],为此本文对自适应律进行了改进.从上述 $\hat{\cdot}$ 的表达式可以看出,自适应律中增加了参数 $\tilde{\cdot}$,其目的是改善系统的过渡过程品质,定义如下:

$$i_j = 1/[1 + \exp(-(t - c_{ij})/d_{ij})], \quad (17)$$

其中 c_{ij} 和 d_{ij} 为大于零的常数.下面对参数 $\tilde{\cdot}$ 的作用作简单的说明.考虑 $\tilde{\cdot} = 0$ 附近的 Jacobian 矩阵

$$J = \frac{\partial \tilde{\cdot}}{\partial \tilde{\cdot}} = \frac{\partial \hat{\cdot}}{\partial \tilde{\cdot}} = \frac{\partial [i_1 S_1^T - i_1 \tilde{\cdot} - i_1 \cdot]}{\partial \tilde{\cdot}} = -i_1 i_1 = -\text{diag}[i_1 i_j], j = 1, 2, \dots, l. \quad (18)$$

J 可以看作 $\tilde{\cdot} = i_1 i_1 [i_1 S_1^T - i_1 \tilde{\cdot} - i_1 \cdot]$ 的特征值矩阵.由式(18)可以看出,神经网络的收敛速度是动态变化的,在 NN 学习初期特征值较小,NN 的误差收敛速度小,可以避免系统振荡,随着时间的增加收敛速度逐渐增大,可以精确补偿系统的不确定性.

3.2 稳定性分析

为了方便稳定性分析,首先引入如下引理:

引理 1 考虑如下 Lyapunov 函数:

$$V(t) = \frac{1}{2} [E^T(t) E(t) + \text{tr}(\bar{W}^T(t) \bar{W}(t)) + h^T(t) h(t)], \quad (19)$$

其中: $E(t) = x(t) - x_d(t)$, $h(t) = x_d(t) - \bar{x}_d(t)$, $x(t) \in R^n$, $x_d(t) \in R^n$, $\bar{x}_d(t) \in R^n$, 为正定阵.

$\bar{W}(t) = W(t) - W^*$, $W^* \in R^{m \times n}$ 为常数矩阵,其范数有界,如果下列不等式成立(μ_1, μ_2 为大于零的常数):

$$\dot{V}(t) \leq -\mu_1 V(t) + \mu_2, \quad (20)$$

则给定初始紧集 $\Omega_0 = \{x(0), W(0), h(0) \mid x(0), W(0), h(0) \text{ 有界}\}$,可得如下结论:

(a) $W(t) \leq c_{\bar{W}} + W^*$, 即 $W(t)$ 有界,其中 $c_{\bar{W}} = \sqrt{2 \mu_2 / \mu_1}$, μ_1 为矩阵 \bar{W} 的最小特征值.

(b) $E(t), \bar{W}(t)$ 及 $h(t)$ 指数收敛至有界紧集 Ω_c 内,即

$$\Omega_c = \{ \bar{W}(t), E(t), h(t) \mid \lim_{t \rightarrow \infty} E(t) = \mu_E^*, \lim_{t \rightarrow \infty} \bar{W}(t) = \mu_{\bar{W}}^*, \lim_{t \rightarrow \infty} h(t) = \mu_h^* \},$$

其中 $\mu_{\bar{W}}^* = \sqrt{2 \mu_2 / \mu_1}$, $\mu_E^* = \sqrt{2 \mu_2 / \mu_1}$.

(c) 若 $x_d(t) \in R^n$ 有界, 则 $x(t)$ 有界, 其中 $c_x = \max_{t \in [0, t]} \|x_d(t)\| + c_x$, 即 $x(t)$ 有界, 其中 $c_x = \sqrt{2V(0)}$.

证明 对式(20)两边从 $[0, t]$ 积分得

$$V(t) \leq [V(0) - \mu_2 / \mu_1] e^{-\mu_1 t} + \mu_2 / \mu_1, \quad (21)$$

对上式进行缩放得 $V(t) \leq V(0)$. 由式(19)知

$$\frac{\bar{W}(t)}{\sqrt{2 \mu_2 / \mu_1}} \leq \sqrt{\frac{\text{tr}[\bar{W}^T(t) \bar{W}(t)]}{\mu_1}} \leq \sqrt{2 \mu_2 / \mu_1} V(0),$$

由 $\bar{W}(t) = W(t) - W^*$ 可知 $W(t) \leq W^* + \bar{W}(t)$, 即(a)得证.

由式(21)知

$$E(t) \leq \sqrt{2 [V(0) - \mu_2 / \mu_1] e^{-\mu_1 t} + 2 \mu_2 / \mu_1}, \quad (22)$$

$$\sqrt{2 \mu_2 / \mu_1} [V(0) - \mu_2 / \mu_1] e^{-\mu_1 t} + \mu_2 / \mu_1, \quad (23)$$
$$h(t) \leq \sqrt{2 [V(0) - \mu_2 / \mu_1] e^{-\mu_1 t} + 2 \mu_2 / \mu_1}. \quad (24)$$

如果 $V(0) \leq \mu_2 / \mu_1$, 则 $\forall t \geq 0, E(t) \leq \mu_E^*$. 若 $V(0) > \mu_2 / \mu_1$, 由式(22)可知对于任意给定的 $\mu_E > \mu_E^*$, 存在 T_E , 使得当 $t > T_E$ 时, $E(t) > \mu_E$. 令

$$\mu_E = \sqrt{2 [V(0) - \mu_2 / \mu_1] e^{-\mu_1 T_E} + 2 \mu_2 / \mu_1},$$

若取 $T_E = -\frac{1}{\mu_1} \ln \left[\frac{\mu_E^2 - 2 \mu_2 / \mu_1}{2(V(0) - \mu_2 / \mu_1)} \right]$, 则当 $t > T_E$ 时, $E(t) > \mu_E$, 并且可以得到 $\lim_{t \rightarrow \infty} E(t) = \mu_E^*$, 同样可得 $\lim_{t \rightarrow \infty} \bar{W}(t) = \mu_{\bar{W}}^*$, $\lim_{t \rightarrow \infty} h(t) = \mu_h^*$, 即(b)得证.

由式(19)及 $V(t) \leq V(0)$ 可知, $E(t) \leq \sqrt{2V(0)}$, 因 $x_d(t)$ 有界, 由 $E(t) = x(t) - x_d(t)$ 可知 $x(t) \leq x_d(t) + E(t) \leq c_x$, 即(c)得证. 因此引理 1 得证.

引理 2^[12] 设 $V: D \rightarrow R$ 是定义域为 $D \subset R^n$ 且包含原点的连续正定函数, 且 $V(x)$ 径向无界, 则对任意 $x \in R^n$, 存在 K 类函数 ϕ_1 和 ϕ_2 在 $[0, \infty)$ 上有定义, 使得 $\phi_1(x) \leq V(x) \leq \phi_2(x)$.

定义闭环系统(1)的边界层误差

$$b_{i+1} = z_{i+1} - \bar{x}_{i+1}, \quad 1 \leq i \leq n-1, \quad (25)$$

对其求导得

$$\dot{b}_{i+1} = -b_{i+1} / \tau_{i+1} - \dot{\bar{x}}_{i+1} = -b_{i+1} / \tau_{i+1} - P_{i+1},$$

其中矩阵函数 $P_{i+1} = \begin{bmatrix} \frac{\partial \bar{x}_{i+1}}{\partial s_{i-1}}, \frac{\partial \bar{x}_{i+1}}{\partial s_i}, \frac{\partial \bar{x}_{i+1}}{\partial \hat{\cdot}}, \frac{\partial \bar{x}_{i+1}}{\partial \cdot} \\ \frac{\partial \bar{x}_{i+1}}{\partial z_i}, \frac{\partial \bar{x}_{i+1}}{\partial f_i}, \frac{\partial \bar{x}_{i+1}}{\partial g_{i-1}}, \frac{\partial \bar{x}_{i+1}}{\partial g_i} \end{bmatrix}$. 由引理 2 知存在 K 类函数 $\phi_{(i+1)1}$ 和 $\phi_{(i+1)2}$, 使得

$$\phi_{(i+1)1}(\|X_{i+1}\|) \leq P_{i+1} \leq \phi_{(i+1)2}(\|X_{i+1}\|), \quad (26)$$

其中 X_{i+1} 为 P_{i+1} 的状态向量.

由式(25)及 $S = x_2 - z_2$ 得 $x_2 = S_2 + \bar{x}_2 + b_2$,

将其代入式(7)得

$$\dot{S}_i = -k_i S_i + g_i S_2 - \tilde{g}_{i-1}^T S_{i-1} + g_i b_2, \quad (27)$$

同理可得

$$\dot{S}_i = -k_i S_i + g_i S_{i+1} - \tilde{g}_i^T S_i - g_{i-1}^T S_{i-1} + g_i b_{i+1}, \quad (28)$$

$$\dot{S}_n = -k_n S_n - \tilde{g}_n^T S_n - g_{n-1}^T S_{n-1} + g_n. \quad (29)$$

定理 1 考虑闭环系统(1), 给定已知有界输入参考信号 y_r 以及初始紧集

$$\Omega = \left\{ \sum_{i=1}^n S_i^2 + \sum_{i=1}^n \text{tr}[\tilde{g}_i^T \Lambda_i^{-1} \tilde{g}_i] + \sum_{i=1}^{n-1} b_{i+1}^2 \right\},$$

为给定的任意正数. 在假设 1 ~ 假设 3 的条件下, 采用控制律及神经网络自适应律(8, 12, 16), 则选择适当的控制器参数 $k_i, \lambda_i, \Lambda_i$ 可保证闭环系统所有信号有界, 系统的跟踪误差及神经网络权值估计误差指数收敛于有界紧集内.

证明 定义闭环系统(1)的 Lyapunov 函数

$$V = \frac{1}{2} \sum_{i=1}^n [S_i^T S_i + \text{tr}(\tilde{g}_i^T \Lambda_i^{-1} \tilde{g}_i)] + \frac{1}{2} \sum_{i=1}^{n-1} b_{i+1}^T b_{i+1}, \quad (30)$$

对 V 按时间 t 求导并由 $d \Lambda_i^{-1} / dt = 0$ 得

$$\dot{V} = \sum_{i=1}^n S_i^T \dot{S}_i + \sum_{i=1}^n \text{tr}[\tilde{g}_i^T \Lambda_i^{-1} \dot{\tilde{g}}_i] + \sum_{i=1}^{n-1} b_{i+1}^T \dot{b}_{i+1}. \quad (31)$$

将式(27) ~ (29) 及自适应律代入上式得

$$\dot{V} = \sum_{i=1}^n [-k_i S_i^2 + S_i^T g_i] + \sum_{i=1}^{n-1} S_i^T g_i b_{i+1} - \sum_{i=1}^n \text{tr}[\tilde{g}_i^T \Lambda_i^{-1} \dot{\tilde{g}}_i] - \sum_{i=1}^{n-1} [b_{i+1}^2 / \lambda_{i+1} + b_{i+1}^T P_{i+1}]. \quad (32)$$

由不等式

$$\begin{aligned} S_i^T b_{i+1} &\leq S_i^2 + b_{i+1}^2 / 4, \\ S_i^T g_i &\leq S_i^2 + g_i^2 / 4, \\ \text{tr}[\tilde{g}_i^T \Lambda_i^{-1} \dot{\tilde{g}}_i] &\leq \lambda_i^* S_i^2 - 2 \text{tr}[\tilde{g}_i^T \Lambda_i^{-1} \dot{\tilde{g}}_i], \\ b_{i+1}^T P_{i+1} &\leq \lambda_{i+1} / 2 + b_{i+1}^2 - P_{i+1}^2 / 2 \lambda_{i+1}, \end{aligned}$$

得

$$\begin{aligned} \dot{V} &\leq - \sum_{i=1}^n k_i^* S_i^2 - \frac{1}{2} \min_{i=1}^n \max_{i=1}^n \text{tr}[\tilde{g}_i^T \Lambda_i^{-1} \dot{\tilde{g}}_i] + \sum_{i=1}^{n-1} - [1 / \lambda_{i+1} - g_{i+1} / 4 - \lambda_{i+1} / 2] b_{i+1}^2 + \end{aligned}$$

$$\begin{aligned} \phi + \sum_{i=1}^{n-1} [P_{i+1}^2 - b_{i+1}^2 / 2 \lambda_{i+1} - (i+1) / 2] b_{i+1}^2 / 2 \lambda_{i+1}. \quad (33) \end{aligned}$$

其中

$$\lambda_{i+1}^* = \min\{\lambda_i\}, \quad k_i^* = k_i - 1 - g_{i+1},$$

$$\phi = \sum_{i=1}^n [g_i^2 / 4 + \min_{i=1}^n \lambda_i^* / 2] + \sum_{i=1}^{n-1} \lambda_i / 2,$$

λ_i 为任意正实数, $\max(\lambda_i)$ 表示矩阵 Λ_i 的最大特征值. 令

$$\tilde{\lambda} = \min\{k_i^*, \min_{i=1}^n \max(\lambda_i) / 2\},$$

$$\lambda_i = (i+1) / 2 [2(1 / \lambda_{i+1} - g_{i+1} / 4 - \tilde{\lambda})],$$

则式(33)可转化为

$$\dot{V} \leq -2\tilde{\lambda} V + \phi \quad (34)$$

当 $\tilde{\lambda} > \phi / 2$ 时, 有 $\dot{V} < 0$.

令 $E(t) = [S_1^T, S_2^T, \dots, S_n^T]^T, x_d(t) = [x_{1d}^T, z_2^T, \dots, z_n^T]^T, \bar{x}_d(t) = [x_{1d}^T, \bar{x}_2^T, \dots, \bar{x}_n^T]^T, W(t) = [1^T, \tilde{\lambda}^T, \dots, \tilde{\lambda}^T]^T, \Lambda = \text{diag}\{\lambda_i\}$, 则式(30)可转化为式(19)的形式.

由引理 1(a) 知

$$\begin{aligned} W(t) &\leq \sqrt{2 \min(\lambda_i) V(0) + W^*} \\ &\leq \sqrt{2 \min\{\lambda_i\} \phi + W^*}, \end{aligned}$$

即神经网络的权值估计有界, (λ_i) 表示矩阵 Λ_i 的特征值.

由引理 1(b) 可知

$$\begin{aligned} \lim_{t \rightarrow \infty} E(t) &= \sqrt{\phi}, \\ \lim_{t \rightarrow \infty} \bar{W}(t) &= \sqrt{\min\{\lambda_i\} \phi}. \end{aligned}$$

因 $W(t)$ 和 $E(t)$ 有界, 由式(8)知 \bar{x}_2 有界, 即 z_2 和 \dot{z}_2 有界. 由式(12)可知 \bar{x}_3 有界, 以此类推可得 $x_d(t)$ 有界, 从而由引理 1(c) 可知

$$x(t) \leq \max_{[0, t]} |x_d(t)| + \sqrt{2}.$$

定理 1 得证.

注 2 本文使用的神经网络数少于文献[7], 且设计的参数自适应律无需投影算法即可保证神经网络估计值保持在有界闭集内.

注 3 $E(t)$ 的收敛域大小受参数 $k_i^*, \lambda_i, \Lambda_i$ 的影响, 一般情况下可选取参数 $k_i^* > \min_{i=1}^n \max(\lambda_i) / 2$. 这时随着 λ_i 或 $\min_{i=1}^n \lambda_i$ 的增大, 收敛域减小. 但 $\lambda_i, \min_{i=1}^n \lambda_i$ 的值不能取太大, 否则会达到相反的效果.

4 仿真验证

4.1 数值模型仿真

考虑如下不确定非线性系统:

$$\begin{aligned} \dot{x}_{11} &= x_{21} + 0.5 x_{11}^2 \sin(2t), \\ \dot{x}_{12} &= x_{22} + 0.2 [x_{11}^2 + x_{12}^2] \cos(2t), \\ \dot{x}_{21} &= x_{21} x_{22} + 0.5 [1 + x_{11}^2] u_1 + 0.6 \sin x_{21}, \end{aligned}$$

$$\begin{aligned} \dot{x}_{22} &= x_{22} + x_{21} x_{22} + 0.5[1 + x_{12}^2]u_2 + \\ &0.5[x_{21}^2 + x_{22}^2]\sin^3 t, \\ y_1 &= x_{11}, y_2 = x_{12}. \end{aligned} \tag{35}$$

控制目标是使输出 y_1, y_2 稳定跟踪参考轨迹 $y_{r1} = \sin t, y_{r2} = 0.5[\sin t + \sin(0.5t)]$. 控制器参数选择为 $k_1 = 12, k_2 = 8, \tau_1 = \text{diag}[10], \tau_2 = \text{diag}[4], \tau_{11} = \tau_{12} = 2, \tau_{21} = \tau_{22} = \text{diag}[1/(1 + \exp(-(t - 1.5)/0.2))]$. 滤波器的时间常数设为 0.01. 图 1 和图 2 给出了输出 y_1, y_2 的仿真曲线, 图中 y_r 为参考轨迹, y_{IDSC} 和 y_{NTD} 分别为改进的动态面控制及文献 [7] 的鲁棒控制方法的仿真结果. 可以看出, 文献 [7] 的方法虽然可以很好地补偿系统的不确定和干扰, 但过渡过程较长且出现了较大的振荡. 本文方法在过渡过程未出现振荡, 且能够很快逼近系统的不确定和干扰, 抑制了过渡过程振荡现象, 说明改进的神经网络自适应率是有效的, 系统具有较好的动态特性和鲁棒性.

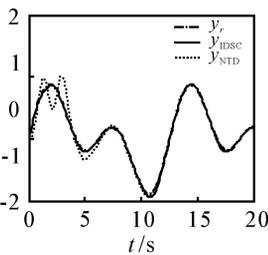
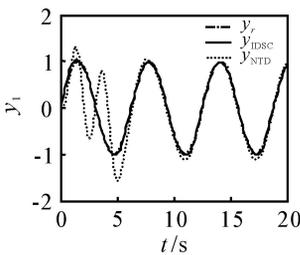


图 1 输出 y_1 的仿真曲线

图 2 输出 y_2 的仿真曲线

4.2 新型战斗机飞行控制仿真

某新型推力矢量战斗机, 其姿态运动学方程描述如下^[13]:

$$\begin{cases} \dot{y} = f_s(\bar{x}_s) + g_{s1}(\bar{x}_s)u + d_1, \\ \dot{z} = f_f(\bar{x}_f) + g_f(\bar{x}_f)u + d_2. \end{cases} \tag{36}$$

其中: $y = [\alpha, \beta, \mu]^T$ 为姿态角向量; $\dot{y} = [p, q, r]^T$ 为姿态角速度向量; $\bar{x}_s = [V, \gamma, \delta, \mu]^T, \bar{x}_f = [T, V, \delta, \mu, p, q, r]^T; T, V, \delta, \mu, p, q, r$ 相对于姿态向量来说是慢变量, 因此设计姿态控制系统时将其视为常量; $u = [\delta_a, \delta_c, \delta_r, \delta_y, \delta_z]^T$ 为控制舵面偏转; f_s, g_{s1}, f_f, g_f 为标称系统的非线性向量或矩阵函数, 其具体含义见文献 [13]; $d_1 = f_s + g_{s2}u + d_1, d_2 = f_f + g_f u + d_2$ 为气动参数摄动引起的不确定及外界干扰. 控制目标是使飞机的姿态角 y 稳定跟踪期望的制导指令 y_c .

假设飞机作超音速飞行, 速度为 Mach1.5, 飞行高度为 10 km, 发动机推力为 125 kN. 初始姿态角为 $\alpha_0 = 4^\circ, \beta_0 = 2^\circ, \mu_0 = 20^\circ$, 制导指令为 $\alpha_c = 6^\circ, \beta_c = 0^\circ, \mu_c = 0^\circ$. 控制器参数同上述数值模型. 假设飞行过程中全部力矩系数比额定值减少 50%, 升力系

数比额定值减少 50%, 阻力和侧力系数比额定值增加 50%. 另外, 在滚转、俯仰、偏航通道分别加入 $1.9 \times 10^4, 1.5 \times 10^4, 3.9 \times 10^4 \sin t$ (kN·m) 的力矩干扰. 六自由度仿真结果如图 3 ~ 图 6 所示.

图 3 ~ 图 5 为姿态角 α, β, μ 的跟踪曲线, 可以看出仿真曲线超调较小, 过渡过程较平滑. 图 6 给出了控制舵面偏转的仿真曲线.

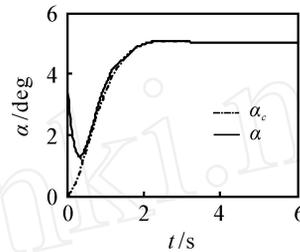


图 3 迎角跟踪曲线

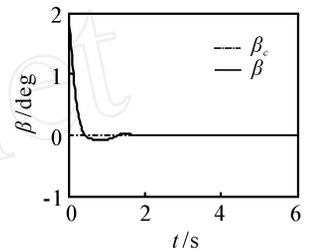


图 4 侧滑角跟踪曲线

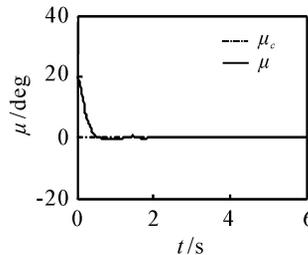


图 5 滚转角跟踪曲线

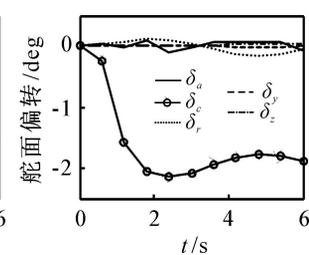


图 6 舵面偏转

5 结 论

本文在现有的反推自适应神经网络控制方法基础上, 针对其不足, 研究了一种鲁棒自适应动态面控制方法, 利用动态面控制降低控制器复杂性, 同时改进自适应律使之可以动态调节神经网络估计误差的收敛速度, 显著改善了系统的过渡过程品质. 利用 Lyapunov 方法证明了闭环系统的稳定性. 仿真结果表明, 本文方法在减少控制律复杂程度的同时, 系统仍保持良好的过渡过程品质且具有一定的鲁棒性.

参考文献(References)

- [1] Li Y, Qiang S, Zhuang X, et al. Robust and adaptive backstepping control for nonlinear systems using RBF neural networks[J]. IEEE Trans on Neural Networks, 2004, 15(3): 693-201.
- [2] Ge S S, Wang C. Adaptive neural control of uncertain MIMO nonlinear systems[J]. IEEE Trans on Neural Networks, 2004, 15(3): 674-692.
- [3] Hwang J P, Kim E. Robust tracking control of an electrically driven robot: Adaptive fuzzy logic approach [J]. IEEE Trans on Fuzzy System, 2006, 14(2): 232-247.
- [4] Lee T Y, Kim Y D. Nonlinear adaptive flight control using backstepping and neural networks controller[J]. J of Guidance, Control and Dynamics, 2001, 24(4): 675-

- 682.
- [5] 胡云安, 晋玉强, 崔平远. 带有广义不确定性的导弹非线性控制系统设计[J]. 航空学报, 2004, 25(2): 153-157.
(Hu Y A, Jin Y Q, Cui P Y. Nonlinear controller design for missile system with a general set of uncertainties [J]. Acta Aeronautica and Astronautica Sinica, 2004, 25(2): 153-157.)
- [6] 刘燕斌, 陆宇平. 基于反步法的高超音速飞机纵向逆飞行控制[J]. 控制与决策, 2007, 22(3): 313-317.
(Liu Y B, Lu Y P. Longitudinal inversion flight control based on backstepping for hypersonic vehicle [J]. Control and Decision, 2007, 22(3): 313-317.)
- [7] 胡云安, 晋玉强, 张友安, 等. 基于神经网络的严反馈块非线性系统的鲁棒控制[J]. 控制与决策, 2004, 19(7): 808-812.
(Hu Y A, Jin Y Q, Zhang Y A, et al. NN based robust control for strict-feedback block nonlinear systems [J]. Control and Decision, 2004, 19(7): 808-812.)
- [8] 董文瀚, 孙秀霞, 林岩. 反推自适应控制的发展及应用[J]. 控制与决策, 2006, 21(10): 1081-1087.
(Dong W H, Sun X X, Lin Y. Adaptive backstepping control: Development and applications [J]. Control and Decision, 2006, 21(10): 1081-1087.)
- [9] Swaroop S, Hedrick J K, Yip P P, et al. Dynamic surface control for a class of nonlinear systems [J]. IEEE Trans on Automatic Control, 2000, 45(10): 1893-1899.
- [10] Wang D, Huang J. Neural network-based adaptive dynamic surface control for a class of uncertain nonlinear systems in strict-feedback form [J]. IEEE Trans on Neural Networks, 2005, 16(1): 195-202.
- [11] 李红春, 张天平. 基于动态面控制的 MIMO 自适应神经网络控制[J]. 扬州大学学报, 2006, 9(4): 17-24.
(Li H C, Zhang T P. MIMO adaptive neural network control using dynamic surface control [J]. J of Yangzhou University, 2006, 9(4): 17-24.)
- [12] Khalil H K. 非线性系统[M]. 第 3 版. 北京: 电子工业出版社, 2005.
(Khalil H K. Nonlinear systems[M]. 3rd ed. Beijing: Publishing House of Electronics Industry, 2005.)
- [13] 陈谋. 不确定非线性综合火力/飞行/推进系统鲁棒控制方法研究[D]. 南京: 南京航空航天大学, 2004.
(Cheng M. Research on robust control method for uncertain nonlinear integrated fire/flight/propulsion system [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2004.)

(上接第 937 页)

- [5] Suykens J A K, Vandewalle J. Least square support vector machine classifiers [J]. Neural Processing Letters, 1999, 9(3): 293-300.
- [6] Gestel T V, Suykens J A K. Benchmarking least squares support vector machine classifiers [J]. Machine Learning, 2004, 54(1): 5-32.
- [7] 王定成, 姜斌. 在线稀疏最小二乘支持向量机回归的研究[J]. 控制与决策, 2007, 22(2): 132-137.
(Wang D C, Jiang B. Online sparse least square support vector machines regression [J]. Control and Decision, 2007, 22(2): 132-137.)
- [8] 朱永生, 王成栋. 二次损失函数支持向量机性能的研究[J]. 计算机学报, 2003, 26(8): 982-989.
(Zhu Y S, Wang C D. Experimental study on the performance of support vector machine with squared cost function [J]. Chinese J of Computers, 2003, 26(8): 982-989.)
- [9] Mangasarian O L, Musicant D R. Lagrangian support vector machines [R]. Madison: University of Wisconsin, 2000.
- [10] Mangasarian O L, Musicant D R. Active support vector machine classification [R]. Madison: University of Wisconsin, 2000.
- [11] Golub G H, Van C F. Matrix computations [M]. 3rd ed. Baltimore: The John Hopkins University Press, 1996.