

文章编号: 1001-0920(2008)11-1315-06

一种基于 DTFEL 的非线性自适应逆控制

韩 华¹, 罗 安²

(1. 中南大学 信息科学与工程学院, 长沙 410083; 2. 湖南大学 电气与信息工程学院, 长沙 410082)

摘 要: 提出一种基于离散时间反馈误差学习 (DTFEL) 的两自由度非线性自适应逆控制 (AIC) 方法, 其控制器由动态 RBF 神经网络 (DRBFNN) 前馈控制器和参数固定的 PD 反馈控制器构成. PD 控制器用来保证闭环系统稳定, 动态 RBF 神经网络以 PD 控制器输出和反馈误差的线性组合为学习信号, 通过一种改进的 NLMS (VS MNLMS) 算法在线学习和逼近对象的动态逆, 提高反馈控制器的性能. 稳定性分析证明了该 AIC 系统稳定. 数字仿真结果表明, 该 AIC 具有良好的自适应能力和鲁棒性, 是一种有效的非线性控制方法.

关键词: 离散时间误差反馈学习; 自适应逆控制; 动态 RBF 神经网络; VS MNLMS; PD 控制器

中图分类号: TP202

文献标识码: A

DTFEL-based nonlinear adaptive inverse control

HAN Hua¹, LUO An²

(1. School of Information Sciences and Engineering, Central South University, Changsha 410083, China; 2. College of Electrical and Information Engineering, Hunan University, Changsha 410082, China. Correspondent: HAN Hua, E-mail: han_shannon@126.com)

Abstract: This paper proposes a discrete-time feedback-error-learning (DTFEL) based adaptive inverse control (AIC) strategy with a architecture of two-degree-of-freedom control, the controller consists of a fixed PD feedback controller and a dynamic RBF neural network feedforward controller. PD controller is used to ensure the stability of the closed system. The DRBFNN is driven to approximate the dynamic inverse model of plant by the linear combination of the output of the PD controller and the feedback error signal using the proposed VS MNLMS algorithm. The proposed AIC system is proved to be stable. Practical simulation results show that the AIC exhibits excellent adaptive ability and robustness performance, and it is an efficient nonlinear control strategy.

Key words: DTFEL; Adaptive inverse control; Dynamic RBF neural network; VS MNLMS; PD controller

1 引 言

由于自适应逆控制 (AIC) 性能很大程度上取决于逆模型的精确性, 作为逆模型辨识器的自适应滤波器及其自适应算法就成了 AIC 的研究热点. 目前, 动态 NARX (Nonlinear autoregressive exogenous input) 神经网络是非线性 AIC 常用的自适应滤波器^[1-3]. 但当 NARX 网络作为逆模型逼近器时, 由于不知道滤波器的期望响应, 只知道系统的期望响应, 需用 BPTM-RTRL, BPTM-BPTT 或 BPTM-DDEKF 等非线性算法将系统误差转换为控制器的输出误差来完成控制器的自适应过程^[1]. 而由 Kawato 提出的反馈误差学习 (FEL) 法, 无需误

差信号的转换, 只需直接利用闭环系统的反馈误差训练神经网络, 是一种“目标指引”的控制方法. 与传统的“先学习后控制”方法相比, 该方法能同时完成在线学习和控制^[3]. 基于 FEL 的线性 AIC 现已比较成熟, 而且对于弱非线性对象, FEL 控制方法仍使用, 因为在反馈控制使系统稳定的过程中, 前馈控制器仅起补偿的作用^[4]. 但基于 FEL 的非线性控制方法研究基本上只限于连续 FEL, 而大多数 AIC 系统的控制器是数字控制器, 直接采用连续 FEL 方法并不合适^[5]. 由此, 本文用反馈 RBF 网络与自适应 LMS 滤波器构成动态 RBF 网络 (DRBFNN) 前馈控制器, 并结合 PD 反馈控制, 实现一种两自由度的

收稿日期: 2007-08-29; 修回日期: 2008-02-01.

基金项目: 国家自然科学基金项目 (60474041); 国家 863 计划项目 (2004AA001032); 国家创新基金项目 (05C26224301154).

作者简介: 韩华 (1970—), 女, 湖南湘阴人, 副教授, 博士生, 从事自适应控制、自适应滤波等研究; 罗安 (1957—), 男, 长沙人, 教授, 博士生导师, 从事电力系统自动化、智能控制等研究.

DTFEL 非线性 AIC.

2 基于 DTFEL 的非线性 AIC 结构

根据 FEL 原理^[6],本文提出基于 DTFEL 的两自由度模型参考自适应逆控制结构,如图 1 所示.其中:前馈控制器为 DRBFNN,反馈控制器为传统的 PD 控制器,控制量为 $u(k) = u_{bf}(k) + u_{ff}(k)$.若在引入神经网络前,PD 控制使系统闭环稳定,则在引入神经网络后,FEL 自适应逆控制的目标是使 $\lim_k e(k) = 0$ 和 $\lim_k u_{bf}(k) = 0$.此时,神经网络将逼近对象逆,系统输出精确跟踪输入.神经网络的学习过程实际上是一个使反馈控制器输出趋于 0 的过程,因此,可取 $J = \frac{1}{2} u_{bf}^2(k)$ 为神经网络学习过程的性能指标.对于实际的控制系统,稳态误差可能很小,但一般并不为零.因此为了确保反馈控制器的输出和反馈误差都尽可能小,本文将神经网络的训练信号 $k = 1 u_{bf}(k) + 2 e(k)$,相应的性能指标 $J = \frac{1}{2} k$,其中 1 和 2 均为不大于 1 的正数.

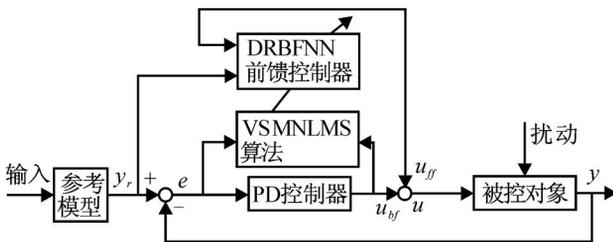


图 1 基于 FEL 的模型参考 AIC 结构图

3 被控对象与控制器

3.1 被控对象

本文的研究对象为 SISO 离散时间非线性系统,即

$$y(k+d) = f(y_k, u_k),$$

$$y_k = [y(k), y(k-1), \dots, y(k-n+1)],$$

$$u_k = [u(k), u(k-1), \dots, u(k-m+1)]. \quad (1)$$

其中: f 为未知的非线性函数; m 和 n 分别为输入和输出时间序列的阶次, $m < n$; d 为保证系统逆存在的系统延迟; y_k 和 u_k 分别为对象的输出和输入时间序列.对象(1)满足以下条件:

- 1) $f(0, 0, \dots, 0) = 0$;
- 2) $f(\cdot)$ 关于 $y(k), \dots, y(k-n+1), u(k), \dots, u(k-m+1)$ 连续可导,且各偏导数有界,即 $|\partial f / \partial y| \leq r, |\partial f / \partial u| \leq r$, 其中 r 为非负数.

3.2 反馈控制器

反馈控制器的参数应在引入神经网络之前整定,在保证闭环系统稳定后,固定反馈控制器并在线学习和调整前馈控制器的参数,以改善传统反馈控制的控制性能^[7].由于并不要求 PD 控制器是最优

的,只要存在使系统闭环稳定的 PD 控制器,参数的整定并不困难.

3.3 前馈控制器

为使前馈控制器逼近非线性对象的逆,考虑到 RBF 神经网络的结构特点和强大的逼近性能,本文将 AIC 系统前馈控制器设计为动态 RBF 神经网络(DRBFNN),并提出由 RBF 网络与自适应 LMS 滤波器集成的非线性自适应滤波器,如图 2 所示.由于反馈信号的存在,DRBFNN 的上部分为 IIR 滤波器,下部分为反馈 RBF 网络.下面将根据滤波器结构推导 DRBFNN 输入输出映射的非线性函数.

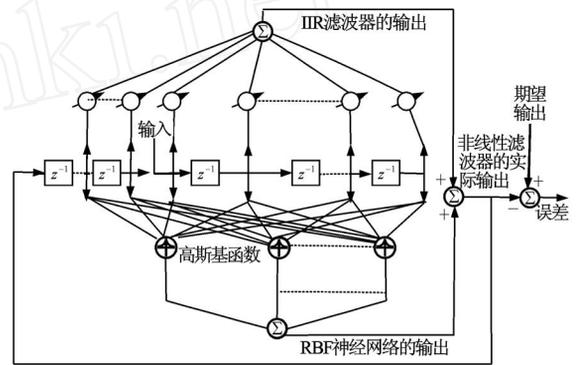


图 2 基于反馈 RBF 网络的非线性自适应滤波器

对于图 2,设 $x_k = [x(k), x(k-1), \dots, x(k-n+1)]^T$ 和 $u_{k-1} = [u_{ff}(k-1), u_{ff}(k-2), \dots, u_{ff}(k-m)]^T$ 分别表示滤波器给定和反馈输入时间序列; $x(k)$ 和 $u_{ff}(k)$ 分别表示第 k 次迭代时 DRBFNN 的给定输入和实际输出; m 和 n 分别为反馈输入和给定输入抽头延迟线的长度,且 $m < n$.由此,DRBFNN 的实际输入时间序列为 $\hat{x}_k = [x_k^T, u_{k-1}^T]^T$.

对于 RBF 网络部分,设 RBF 网络隐层的输出向量为 $h_k = [h_1(k), h_2(k), \dots, h_M(k)]^T$,其中 $h_j(k) = \exp(-\|\hat{x}_k - c_j\|^2 / 2\sigma_j^2)$ ($j = 1, 2, \dots, M$) 为高斯基函数, M 为隐层单元数;设 RBF 网络节点 j 的中心矢量为 $c_j = [c_{j1}, c_{j2}, \dots, c_{jn}, \dots, c_{j(n+m)}]^T$,网络的宽泛向量为 $\sigma = [\sigma_1, \sigma_2, \dots, \sigma_M]^T$,其中 $\sigma_j > 0$ 为节点 j 的宽泛度参数;设网络隐层到输出的权向量为 $w_k = [w_1(k), w_2(k), \dots, w_M(k)]^T$,则 RBF 网络部分的输出为 $u_r(k) = w_k^T h_k = \sum_{j=1}^M w_j h_j$.

对于 IIR 滤波器,设其抽头权向量为 $\hat{w}_k^T = [\hat{w}_1(k), \hat{w}_2(k), \dots, \hat{w}_n(k), \hat{w}_{n+1}(k), \dots, \hat{w}_{n+m-1}(k)]$,则 IIR 滤波器的输出可表示为 $u_l(k) = \sum_{j=1}^{m+n} \hat{w}_j \hat{x}(k-j+1)$.于是,DRBFNN 滤波器的输入输出描述为

$$u_{ff}(k) = G(\hat{x}_k, u_{k-1}, \tilde{w}_k) =$$

$$\sum_{j=1}^M w_j h_j + \sum_{j=1}^N \hat{w}_j \hat{x}(k-j+1) = \tilde{w}_k^T \tilde{x}_k. \quad (2)$$

根据式(2),若 $\tilde{w}_k = [\hat{w}_k^T, w_k^T]^T$ 和 $\tilde{x}_k = [\hat{x}_k^T, h_k^T]^T$ 分别为 DRBFNN 的等效权向量和输入向量,则该非线性滤波器的权系数与其输出之间呈线性关系,而输入和输出却保持非线性关系.由此,DRBFNN 可采用线性 LMS 算法学习对象逆,从而可避免使用可能陷入局部极小值的非线性算法.

4 DRBFNN 的自适应算法

由 FEL 方法可知,以 $x(k)$ 为训练信号,以 $J = \frac{1}{2} e^2(k)$ 为性能指标,DRBFNN 对非线性逼近对象逆的精确性与该滤波器的自适应算法和 RBF 网络的结构紧密相关.根据 DRBFNN 的结构,本文提出线性 VS MNLMS 算法作为 DRBFNN 权系数的学习算法.同时,采用梯度下降法对 RBF 网络参数进行学习.

4.1 VS MNLMS 自适应算法

为了提高算法的收敛速度和减少稳态 MSE,本文将 NLMS 算法改进后,使其步长同时依赖输入功率估计和误差,并结合文献[8]中对 VS NLMS 算法构成的描述,将该算法用于训练 DRBFNN 权系数.文献[9]中已分析和验证:在 AIC 系统中,VS NLMS 算法比其他 3 种变步长 LMS 算法都有更好的收敛和稳态特性.本文对文献[9]中的仿真对象和 AIC 结构进行仿真分析,其 MSE 学习曲线如图 3 所示.

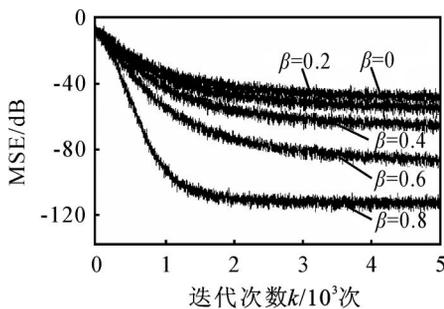


图 3 不同时 VS MNLMS 算法的 MSE 学习曲线

显然当 $\beta = 0$ 时,VS MNLMS 算法即 VS NLMS 算法的收敛性能最差;而当 β 趋近 1 时,VS MNLMS 收敛快且稳态 MSE 小,克服了变步长 LMS 不能兼顾收敛和稳态性能的缺点.具体过程如下:

$$\tilde{w}_{k+1} = \tilde{w}_k + \mu_k \frac{\tilde{x}_k \tilde{x}_k^T}{\tilde{x}_k^T \tilde{x}_k}, \quad (3)$$

$$\mu_k = \mu_{\max} \frac{p_k^2}{(p_k^2 + c)}, \quad (4)$$

$$p_k = p_{k-1} + (1 - \alpha) \frac{\tilde{x}_k^T \tilde{x}_k}{\tilde{x}_k^T \tilde{x}_k}, \quad (5)$$

$$u_{bf}(k) = k_p e(k) + k_d ((e(k) - e(k-1))/T), \quad (6)$$

$$e(k) = r(k) - y(k), \quad (7)$$

$$e(k) = r(k) - y(k), \quad (8)$$

$$\tilde{w}_{k+1} = \tilde{w}_k + \frac{\mu_k}{\left(\sum_{i=k-l+1}^k (i)^2 + (1 - \alpha) \tilde{x}_k^T \tilde{x}_k \right)} \tilde{x}_k \tilde{x}_k^T, \quad (9)$$

$$u_{bf}(k) = k_p e(k) + k_d ((e(k) - e(k-1))/T), \quad (10)$$

$$e(k) = r(k) - y(k), \quad (11)$$

$$e(k) = r(k) - y(k), \quad (12)$$

其中: T 为采样周期; $0 < c; \alpha < 1$ 为小的常数; $0 < l < k$ 为数据窗的长度; k_p, k_d 分别为位置式 PD 控制的比例和微分系数; $y(k)$ 和 $y(k)$ 分别为 VS NLMS 和 VS MNLMS 学习时闭环系统的输出; \tilde{w}_k 为利用 VS NLMS 调节步长 μ_k 时的权向量,为中间变量. VS MNLMS 算法的迭代包括两步:首先,VS NLMS 算法(3)~(8)得到步长 μ_k ;然后,以 μ_k 为初始值,采用式(9)~(12)学习网络的权系数 \tilde{w}_k .该算法稳定的步长范围为 $0 < \mu_k < 2$.

4.2 RBF 网络中心和宽泛参数的自适应算法

RBF 网络的中心向量和宽泛参数的学习采用动量梯度下降法,即

$$c_{ji}(k) = c_{ji}(k-1) + \eta w_j(k) \frac{\hat{x}(k-j+1) - c_{ji}}{j} + (c_{ji}(k-1) - c_{ji}(k-2)) + (c_{ji}(k-2) - c_{ji}(k-3)), \quad (13)$$

$$j(k) = j(k-1) + \eta w_j(k) h_j(k) \frac{\hat{x}_k - c_j}{j} + (j(k-1) - j(k-2)) + (j(k-2) - j(k-3)). \quad (14)$$

其中: η 为学习步长, α 为动量因子.

5 稳定性分析

引理 1^[10] 若系统(1)是逆稳定的,则有

$$\|u(k-1)\| \leq k_1 + k_2 \max_i |y(i)|,$$

其中 $0 < k_1, k_2 < \infty$.

引理 2^[10] 若给出的实标量序列 $\{s(k)\}, \{d_1(k)\}, \{d_2(k)\}$ 和列向量 (k) 满足下述条件:

$$1) \lim_k \frac{s^2(k)}{d_1(k) + d_2(k)^T (k) (k)} = 0;$$

2) $0 < d_1(k), d_2(k) < \dots$, 为一正常数;

3) $(k) \quad o_1 + o_2 \max_k / s(\cdot) /$, 式中 $0 <$

$o_1, o_2 < \dots$

则有

1) $\{ (k) \}$ 有界;

2) $\lim_k s(k) = 0$.

定理1 若非线性系统(1) 满足如下条件:

1) 系统逆稳定;

2) $\partial f / \partial u(k-1) > 0$;

3) 存在 $\tilde{w} = \tilde{w}_d$, 使 $u_{bf} = 0$ 时 $y(k) = y_r(k)$;

4) 在引入神经网络之前, 存在 PD 控制器使系统闭环稳定, 即 $|e(0)| < \dots, 0$.

则由式(1), (9) ~ (12) 表示的闭环系统具有下列性质:

1) 闭环系统的输入 $u(k)$ 和输出 $y(k)$ 有界;

2) $\lim_k e(k) = 0$.

证明 令 $\bar{w} = \tilde{w} - \tilde{w}_d$, 取 $V(k) = \bar{w}_k^T \bar{w}_k = \bar{w}_k^2$, 由定理1 的条件3) 可得, 存在 $u_d(k-1) = \tilde{X}_{k-1}^T \tilde{w}_d$, 使

$$\begin{aligned}
& y_r(k) = \\
& f(y(k-1), \dots, y(k-n), u_d(k-1), \\
& u(k-2), \dots, u(k-m)) = \\
& f(y(k-1), \dots, y(k-n), \\
& \tilde{X}_{k-1}^T \tilde{w}_d, u(k-2), \dots, u(k-m)). \\
& e(k) = y_r(k) - y(k) = \\
& f(y(k-1), \dots, y(k-n), \tilde{X}_{k-1}^T \tilde{w}_d, \\
& u(k-2), \dots, u(k-m)) - (y(k-1), \\
& \dots, y(k-n), (\tilde{X}_{k-1}^T \tilde{w}_{k-1} + u_{bf}(k-1)), \\
& u(k-2), \dots, u(k-m)) = \\
& - (\tilde{X}_{k-1}^T \bar{w}_{k-1} + u_{bf}(k-1)). \tag{15}
\end{aligned}$$

其中: $\partial f / \partial u(k-1) = \mu_{k-1} u(k-1)$, $0 < \mu_{k-1} < 2$.

当采样周期 T 很小时, 由上式可得

$$e(k) + u_{bf}(k-1) = e(k-1) + u_{bf}(k-1) - \tilde{X}_{k-1}^T \bar{w}_{k-1}. \tag{16}$$

若设 $k = \left(\sum_{i=k-l+1}^k (i)^2 \right)$, 则式(9) 可表示为

$$\tilde{w}_{k+1} = \tilde{w}_k + \mu_k \frac{\tilde{X}_k}{k + (1 - \dots)^2}. \tag{17}$$

若取 $k = e(k) + u_{bf}(k) = \mu_1 e(k) + \mu_2 u_{bf}(k)$, 则由式(15) 可得

$$\bar{w}_{k-1} = - \tilde{X}_{k-1}^T \bar{w}_{k-1}. \tag{18}$$

根据式(17), (18) 和定理1 可得

$$V(k) = V(k) - V(k-1) =$$

$$\begin{aligned}
& \bar{w}_k - \bar{w}_{k-1} = \\
& (\bar{w}_{k-1} + \mu_{k-1} \frac{\tilde{X}_{k-1}}{k-1 + (1 - \dots)^2})^T (\bar{w}_{k-1} + \\
& \mu_{k-1} \frac{\tilde{X}_{k-1}}{k-1 + (1 - \dots)^2}) - \bar{w}_{k-1}^T \bar{w}_{k-1} = \\
& (- \frac{2}{r} + \mu_{k-1} \frac{\tilde{X}_{k-1}^2}{k-1 + (1 - \dots)^2}) \times \\
& \frac{\mu_{k-1}^2}{k-1 + (1 - \dots)^2}.
\end{aligned}$$

取 $\mu_{k-1} < 2(1 - \dots) / r$, 有

$$V(k) = (- \frac{2}{r} + \frac{\mu_{k-1}}{1 - \dots}) \frac{\mu_{k-1}^2}{k-1 + (1 - \dots)^2} < 0. \tag{19}$$

同时, VS MNLMS 算法收敛时步长的取值范围为 $0 < \mu_k < 2$, 所以同时满足式(19) 的步长范围应为 $\mu_{\max} (0, d)$, 其中 $d = \min(2(1 - \dots) / r, 2)$.

由式(19) 可得 $V(k) = V(k-1) \dots = V(0)$, 有

$$\tilde{w}_k - \tilde{w}_d < \tilde{w}_{k-1} - \tilde{w}_d < \dots < \tilde{w}_0 - \tilde{w}_d,$$

即 $\lim_k \tilde{w}_k = \tilde{w}_d$, 且有

$$\begin{aligned}
V(k) - V(0) &= \sum_{i=1}^k V(i) = \\
& \sum_{i=1}^k (- \frac{2}{r} + \mu_{i-1} \frac{\tilde{X}_{i-1}^2}{i-1 + (1 - \dots)^2}) \times \\
& \frac{\mu_{i-1}^2}{i-1 + (1 - \dots)^2} \\
& \sum_{i=1}^k (- \frac{2}{r} + \mu_{i-1} / (1 - \dots)) \frac{\mu_{i-1}^2}{i-1 + (1 - \dots)^2}.
\end{aligned}$$

于是

$$\begin{aligned}
& \sum_{i=1}^k \frac{2}{i-1} \\
& \left(\sum_{j=i-1}^{i-1} (j)^2 \right) (1 - \dots) \tilde{X}_{i-1} \\
& \frac{V(0) - V(k)}{\mu(2/r - \mu(1 - \dots))} \\
& \frac{V(0)}{\mu(2/r - \mu(1 - \dots))} \triangleq > 0.
\end{aligned}$$

其中 μ 为最小步长, 则有

$$\lim_k \frac{\mu_k^2}{\left(\sum_{i=k-l+1}^k (i)^2 \right) + (1 - \dots)^2 \tilde{X}_k^2} = 0. \tag{20}$$

由 $|e(0)|$ 和自适应过程中 VS MNLMS 算法收敛可知 $\max_k |e(i)| < \dots$. 由 y_r 有界可得

$$|y(k)| = |y_r(k) - e(k)| < \dots + \max_k |e(i)|. \tag{21}$$

由原系统逆稳定条件和引理 1 可得

$$\| u(k-1) \| \leq k_1 + k_2 \max_{0 \leq i \leq k} \| y(i) \|. \quad (22)$$

综合式(21), (22) 可得, 存在 ϵ_2, ϵ_3 使

$$\| u_{ff}(k-1) \| \leq \epsilon_2 + \epsilon_3 \max_{0 \leq i \leq k} \| e(i) \|; \quad (23)$$

综合式(21) ~ (23) 可知, 存在 ϵ_4, ϵ_5 使

$$\| \tilde{x}_{k-1} \| \leq \epsilon_4 + \epsilon_5 \max_{0 \leq i \leq k} \| e(i) \|. \quad (24)$$

由式(2), (20) 和引理 2 可知: 1) $\{ \tilde{x}_{k-1} \}$ 有界, 系统输入输出有界; 2) $\lim_{k \rightarrow \infty} \tilde{w}_k = \tilde{w}_d$

时 $\lim_{k \rightarrow \infty} u_{bf}(k) = 0$, 结合式(11), (12) 可得

$$\lim_{k \rightarrow \infty} e(k) = 0.$$

6 仿真研究

仿真对象为

$$y(k) = \frac{-0.1y(k-1) + u(k-1)}{1 + y(k-1)^2}.$$

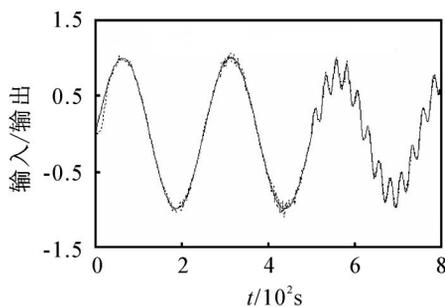
除特别强调外, 仿真实验中参数设置为:

$\alpha = 0.85, \beta = 1, T = 0.1s, n = 3, M = 6, \gamma = 0.15, \delta = 0.05, l = 0, \eta = 0.02, d = 1, m = 2, \rho_1 = 1, \rho_2 = 0.9, K_p = 0.03, K_d = 0.03$, 参考模型的传递函数取 1.

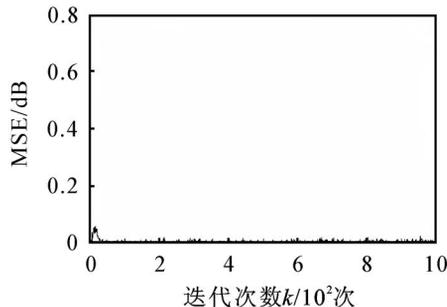
6.1 测量噪声

若输入的正弦信号为

$$r(t) = \begin{cases} \sin(2\pi t/250), & t \leq 500; \\ 0.8\sin(2\pi t/250) + 0.2\sin(2\pi t/25), & t > 500; \end{cases} \quad (25)$$



(a) 正弦输入/输出曲线



(b) FRBFNN的MSE学习曲线

图 4 存在测量噪声时的仿真曲线

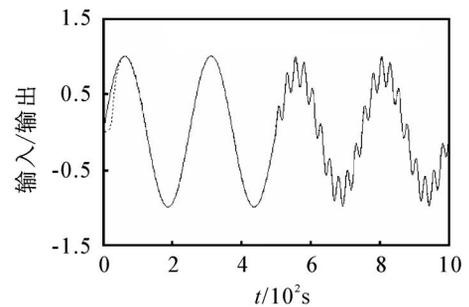
则当系统输出存在方差为 0.01 的白噪声时, 仿真结果如图 4 所示. 图中的实线表示正弦输入; 虚线表示基于 DTFEL 和 DRBFNN 的 AIC 系统输出. 跟踪曲线和 MSE 学习曲线均表明, 存在噪声干扰时, 系统仍具有较好的自适应能力和稳态特性, 并且该 AIC 系统具有较好的设定值跟踪和抗干扰能力.

6.2 模型参数改变

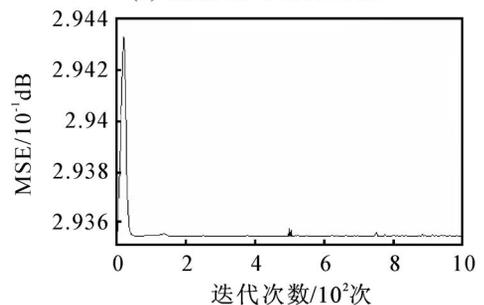
仿真对象为

$$y(k) = \begin{cases} \frac{-0.1y(k-1) + u(k-2)}{1 + y(k-1)^2}, & k \leq 500; \\ \frac{-y(k-1) + 1.25u(k-1)}{1 + y(k-1)^2}, & k > 500. \end{cases} \quad (26)$$

当式(26) 描述的模型参数在第 500 次迭代发生变化时, 相应的仿真结果如图 5 所示. 图中实线和虚线与图 4 中的表示相同. 显然, 尽管模型参数改变了, 基于 FEL 和 VS MNLMS 的 FRBFNN 在线学习速度快, 自适应效果仍非常好.



(a) 正弦输入/输出曲线



(b) FRBFNN的MSE学习曲线

图 5 模型参数变化时的仿真曲线

7 结 论

本文结合传统 PD 控制和 DRBFNN 前馈控制, 实现一种基于 DTFEL 的非线性自适应逆控制方法. 针对 DRBFNN 的结构, 本文提出 VS MNLMS 算法, 并以 PD 控制器的输出和反馈误差的线性组合为训练误差, 在保证 DRBFNN 逼近对象逆的自适应过程的全局收敛性、快速性和精确性的同时, 使动态系统闭环稳定. 仿真结果表明, 即便存在模型参数变化或测量噪声, 本文的 AIC 系统仍具有良好的跟踪设定值和振动抑制能力, 从而验证了本文控制

方法的实用性和有效性.

参考文献(References)

- [1] Gregory L Plett, Hans Böttrich. DDEKF learning for fast nonlinear adaptive inverse control[C]. Proc of the 2002 Int Joint Conf on Neural Network. Honolulu: IEEE, 2002: 2092-2097.
- [2] Gregory L Plett. Adaptive inverse control of linear and nonlinear systems using dynamic neural networks[J]. IEEE Trans on Neural Network, 2003, 14(2): 360-376.
- [3] Liu Ya-qiu, Ma Guang-fu, Jiang Xue-yuan. A design method for adaptive inverse control using NARX neural networks[C]. Proc of the 5th World Conf on Intelligent Control and Automation. Huangzhou, 2004: 459-463.
- [4] 刘亚秋. 基于动态神经网络的自适应逆控制应用研究[D]. 哈尔滨: 哈尔滨工业大学, 2004.
(Liu Y Q. The application research of adaptive inverse control based on dynamic neural network[D]. Harbin: Harbin Institute of Technology, 2004.)
- [5] Sirisak Wongsura, Waree Kongprawechnon. Discrete-time feedback error learning for unknown nonlinear systems [C]. The 2nd Int Conf on Innovative Computing, Information and Control. Kumamoto: IEEE, 2007: 141-144.
- [6] Eiichi Muramatsu, Keiji Watanabe. Feedback error learning control without recourse to positive realness[J]. IEEE Trans on Automatic Control, 2004, 49(10): 1762-1769.
- [7] Ruan Xiao-gang, Liu Liang, Yu Nai-gong, et al. A model of feedback error learning based on Kalman estimator[C]. Proc of the 6th World Conf on Intelligent Control and Automation. Dalian, 2006: 4190-4194.
- [8] Hyun-Chool Shin, Ali H Sayed, Woo-Jin Song. Variable step-size NLMS and affine projection algorithms[J]. IEEE Signal Processing Letters, 2004, 11(2): 132-135.
- [9] Tiebao Yang, Behnam Shahrrava. Performance of variable step-size LMS algorithms for linear adaptive inverse control systems [C]. Conf on Electrical and Computer Engineering. Canadian, 2005: 755-758.
- [10] 古德温, 孙贵生. 自适应滤波、预测与控制[M]. 北京: 科学出版社, 1992.
(Goodwin G C, Sin K S. Adaptive filtering prediction and control[M]. Beijing: Science Press, 1992.)
- [8] Hristu D. Stabilization of LTI systems with communication constraints [C]. Proc of the American Control Conf. Chicago, 2000: 2342-2346.
- [9] Hassibi A, Boyd S P, How J P. Control of asynchronous dynamical systems with rate constraints on events[C]. Proc of the 38th IEEE Conf on Decision and Control. San Diego, 1999: 1345-1351.
- [10] Montestruque L A, Antsaklis P J. Model-based networked control systems: stability [R]. American: University of Notre Dame, 2002.
- [11] Montestruque L A, Antsaklis P J. State and output feedback control in model-based networked control systems[C]. Proc of the 41th IEEE Conf on Decision and Control. Las Vegas, 2002: 1620-1625.
- [12] Montestruque L A, Antsaklis P J. On the modelbased control of networked systems[J]. Automatica, 2003, 39(10): 1837-1843.
- [13] Mu S, Chu T, Hao E, et al. Output feedback control of networked control systems [C]. Proc of IEEE Int Conf on System, Man and Cybernetic. Washington, 2003: 211-216.
- [14] Mu S, Chu T, Hao E, et al. An improved model-based control scheme for networked systems[C]. Proc of IEEE Int Conf on System, Man and Cybernetic. Hague, 2004: 6131-6136.
- [15] 项林英, 郭戈. 基于模型状态反馈的网络化输入多采样率系统[J]. 信息与控制, 2005, 34(3): 380-382.
(Xiang L Y, Guo G. Model-based networked control system with multi-rate input sampling[J]. Information and Control, 2005, 34(3): 380-382.)
- [16] Wang Z W, Fan T C. Model-based networked control systems with multi-rate input sampling [C]. The 3rd Int Conf on Impulsive Dynamical Systems and Application. Qingdao, 2006: 603-608.

(上接第 1314 页)