

考虑非线性执行器的补偿逼近模型控制

袁小芳, 孙 炜, 王耀南, 王 曷

(湖南大学 电气与信息工程学院, 湖南 长沙 410082)

摘要: 考虑执行器的非线性, 研究了一种带补偿的逼近模型控制系统. 该控制系统包含逼近模型控制器与补偿器. 逼近模型控制器根据对象的输入输出线性化关系直接得出控制律, 并由支持向量机辨识对象模型来实现. 补偿部分采用反馈环节来提高系统的鲁棒稳定性, 并采用在线估计得到的逆模型来抵消执行器的非线性特征. 文章分析了该控制系统的稳定性, 针对励磁系统的仿真实验验证了其有效性能.

关键词: 非线性控制; 逼近模型; 执行器的非线性; 系统辨识; 逆模型

中图分类号: TP273 **文献标识码:** A

Compensated approximate model-control with nonlinear actuator

YUAN Xiao-fang, SUN Wei, WANG Yao-nan, WANG Bing

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

Abstract: Considering the actuator nonlinearity, a compensated approximate model-control(CAMC) strategy for the nonlinear plant is presented. This strategy includes the approximate model-controller and the compensator. The approximate model-controller is designed based on the approximate model which is obtained by linearizing the plant input-output relation and implemented by using support-vector-machine(SVM) modeling. In the compensator structure, a feedback filter is employed for ensuring the system stability and robustness; and an online estimated inverse model is used to compensate the actuator nonlinearity. The stability proof of CAMC is derived analytically. Simulations also show the effective application of CAMC to the excitation control in a power system

Key words: nonlinear control; approximate model; actuator nonlinearity; system identification; inverse model

1 引言(Introduction)

在非线性的设计方法中, 直接反馈线性化(DFL)^[1]是基于对象输入-输出描述的一种反馈线性化方法, 已成功解决了多种非线性控制问题. 与DFL方法不同, 近年来研究的一种基于Taylor扩展的直接等效线性化方法, 即逼近模型方法^[2~4], 具有计算简单、设计与实现容易、无需在线调整控制器参数等优点, 在非线性的对象中得到了应用. 文[2,3]设计了基于等效线性化方法的逼近模型控制器(approximate model controller, AMC), 文[4]在AMC的基础上增加了一个反馈环节来提高系统的稳定性, 在前期基础^[2~4]上, 本文将考虑执行器的非线性, 设计了一种补偿逼近模型控制(compensated approximate model control, CAMC)系统, 主要包括逼近模型控制器(AMC)和补偿环节两个部分. AMC仍然采用基于Taylor扩展方法的等效线性化模型, 由此

直接得到控制律, 控制算法只需支持向量机(support vector machines, SVM)^[5,6]来辨识对象模型, 而无需大量的迭代计算或者在线参数调整. 在补偿环节, 采用基于在线估计的逆模型来抵消执行器的非线性. 由于SVM辨识与逆模型建模过程中都存在一定的误差, 因而采用一个反馈补偿环节, 选用合适的鲁棒滤波器来提高控制精度和系统稳定性.

2 CAMC系统结构(CAMC structure)

在现有的控制器设计中, 往往忽略了执行器所普遍存在的“非光滑”(nonsmooth)特性^[7]. 事实上, 这种“非光滑”特性表现出非线性特征, 若不予以考虑, 必将影响到控制器实际应用时的效果. 本文考虑了执行器非线性特征, 所提出的补偿逼近模型控制(CAMC)系统结构如图1所示, 包括一个逼近模型控制器(AMC)和两个补偿部分. AMC用于抵消被控对象的非线性特征. 在补偿部分, 自学习逆模型抵消

执行器的非线性,采用反馈滤波器的反馈补偿在一定程度上消除SVM辨识与逆模型建模误差的影响,提高稳定性.下文将具体分析CMAC系统中各个部分的设计与实现.




图1 CMAC系统结构

Fig. 1 Structure of CMAC

3 AMC设计(AMC design)

3.1 AMC控制律(AMC control law)

对于非线性对象的一种NARMA(nonlinear autoregressive moving average)模型:

$$y(k+1) = f[q(k), u(k)], \quad (1)$$

其中 $q(k) = [y(k), \dots, y(k-n)]$. 可以将式(1)的一种Taylor扩展式表示为^[2]

$$\begin{aligned} y(k+1) &= f[q(k), u(k)] = \\ &f[q(k-1), u(k-1)] + \\ &\sum_{r=1}^{\infty} \frac{1}{r!} \frac{\partial^r f[q(k-1), u(k-1)]}{\partial u(k-1)^r} [u(k) - u(k-1)]^r + \\ &\sum_{r=1}^{\infty} \frac{1}{r!} \frac{\partial^r f[q(k-1), u(k-1)]}{\partial q(k-1)^r} [q(k) - q(k-1)]^r. \end{aligned} \quad (2)$$

依据文[2,3]的分析,在Taylor扩展式中,可以省略留数项 R 得到等效的输入输出方程,即式(2)可等效简化为

$$y(k+1) \approx y(k) + f^1(k-1) \cdot \Delta u(k), \quad (3)$$

其中

$$f^1(k-1) = \frac{\partial f[q(k-1), u(k-1)]}{\partial u(k-1)}. \quad (4)$$

一般地, $f^1(k-1)$ 是一个非线性函数,可以认为其是存在且未知的.根据对象的输入输出数据,本文将由支持向量机(SVM)来辨识 $f^1(k-1)$,将SVM辨识的模型表示为 $\hat{f}^1(k-1)$.这样,控制增量 $\Delta u(k)$ 便可以依据式(3)直接计算得到.在具体计算控制增量 $\Delta u(k)$ 之前,给出以下假设:

假设1 $0 < |f^1(k-1)| \leq g_0$, g_0 为一个有界的正数; $f^1(k-1) = \hat{f}^1(k-1) + \xi(k)$, $\xi(k)$ 为辨识误差,且 $|\xi(k)| \leq \bar{\xi}$, $\bar{\xi}$ 为一个有界的正数;

$$0 \leq \left| \frac{\xi(k)}{\hat{f}^1(k-1)} \right| \leq \xi_0, \xi_0 \text{ 为一个小于1的正数.}$$

假设2 $|y^*(k) - y^*(k-1)| \leq \Delta r$, Δr 为一个有界的正数.

此时,从式(3)中得到逼近模型控制律为^[2]

$$u(k) = u(k-1) + \Delta u(k). \quad (5)$$

其中:当 $|\Delta u(k)| \leq \delta(k)$, $\Delta u(k) = \frac{y^*(k+1) - y(k)}{\hat{f}^1(k-1)}$; 当 $|\Delta u(k)| > \delta(k)$, $\Delta u(k) = \delta(k) \cdot \text{sgn}(\Delta u(k))$. 这里 $y^*(k+1)$ 为期望值, $\text{sgn}(\cdot)$ 为符号函数.在计算控制增量 $\Delta u(k)$ 中,必须满足 $\hat{f}^1(k-1) \neq 0$,这可以由假设1得到.

定义控制误差为

$$e(k) = y^*(k) - y(k). \quad (6)$$

根据式(3),则有

$$\begin{aligned} e(k+1) &= y^*(k+1) - y(k+1) = \\ &y^*(k+1) - y(k) - f^1(k-1) \cdot \\ &\Delta u(k) - R - \gamma - \varepsilon = \\ &y^*(k+1) - y(k) - [\hat{f}^1(k-1) + \xi(k)] \cdot \\ &\Delta u(k) - R - \gamma - \varepsilon. \end{aligned} \quad (7)$$

其中: R 为Taylor扩展中的留数项; γ 描述不确定项和干扰,且 $|\gamma| \leq \gamma_0$, γ_0 为一个有界的正数; ε 描述由于执行器补偿中的偏差.

3.2 AMC的具体实现(Implementation of AMC)

支持向量机(SVM)最初是针对模式识别问题提出来的,后来推广到解决函数回归等问题,目前SVM被公认为是最有效的机器学习方法之一.给定训练数据 $(x_1, y_1), \dots, (x_l, y_l)$ (l 为训练数据的个数),用一个连续函数 $y = f(x)$ 来拟合这些数据时,SVM回归的思想是通过非线性映射 Φ ,将数据 $x(x \in \mathbb{R}^n)$ 映射到高维特征空间 F ,并在高维空间进行线性回归.即

$$f(x) = (w \cdot \Phi(x)) + b, \quad (8)$$

其中: $\Phi: \mathbb{R}^n \rightarrow F$, $w \in F$, w 为权值, $b \in \mathbb{R}$ 为域值.这样,高维特征空间的线性回归便对应于低维输入空间的非线性回归.根据统计学习理论,要求优化损失函数^[5]:

$$\min R_e(w, b) = \frac{1}{l} \sum_{i=1}^l |y_i - w \cdot \Phi(x_i) - b|. \quad (9)$$

约束条件为 $(w \cdot w) \leq C$,控制了函数的复杂性.而 $R_e(w, b)$ 是训练集上的误差.利用Lagrangian方法将式(9)变形后,得到其对偶优化问题为^[6]

$$\max \sum_{i=1}^l y_i(\alpha_i^* - \alpha_i) - \epsilon \sum_{i=1}^l (\alpha_i^* + \alpha_i) - \frac{1}{2} \sum_{i=1, j=1}^l (\alpha_i^* - \alpha_i)(\alpha_j^* - \alpha_j) K(x_i, x_j). \quad (10)$$

约束条件为: $\sum_{i=1}^l \alpha_i^* = \sum_{i=1}^l \alpha_i$, $0 \leq \alpha_i^* \leq C$, $0 \leq \alpha_i \leq C$. 其中: α_i^* , α_i 为Lagrangian系数; ϵ 为不敏感系数; $K(x_i, x_j)$ 为核函数, 是满足Mercer条件的正定函数; 系数 $(\alpha_i^* - \alpha_i)$ 不为0所对应的样本 (x_i, y_i) 就是支持向量(support vectors, SV)^[6]. 这样求解式(10)后就可以由支持向量得到估计的回归函数为

$$y = f(x) = \sum_{i=1}^{SV} (\alpha_i^* - \alpha_i) K(x, x_i) + b. \quad (11)$$

其中SV表示支持向量集, 这里取核函数为 $K(x, x_i) = \exp(-\frac{|x - x_i|^2}{2\sigma^2})$, σ 为宽度参数.

利用SVM来辨识被控对象输入输出关系, 从而得到AMC控制律计算中的 $\hat{f}^1(k-1)$. SVM辨识的结果是用如式(12)所示的回归函数来建立估计的被控对象模型为

$$\hat{y}(k+1) = \hat{f}[Y(k)] = \sum_{t=1}^{SV} (\alpha_t^* - \alpha_t) K[Y(k), Y(t)] + b. \quad (12)$$

其中: $Y(k) = [q(k), u(k)]$, 此时依据式(4)中的定义, 由辨识的模型 $\hat{f}[Y(k)]$ 得到估计的 $\hat{f}^1(k-1)$ 为

$$\begin{aligned} \hat{f}^1(k-1) &= \frac{\partial \hat{f}[Y(k-1)]}{\partial u(k-1)} = \\ &= \frac{u(k-1) \sum_{t=1}^{SV} (\alpha_t^* - \alpha_t) K[Y(k-1), Y(t)]}{-\sigma^2}. \end{aligned} \quad (13)$$

4 非线性执行器的补偿(Compensation of actuator nonlinearity)

4.1 非线性执行器描述(Actuator nonlinearity)

本文中执行器的“非光滑”特性主要考虑了“死区”(dead zone), 用数学模型表示为^[7]

$$u(k) = g(v(k)) = \begin{cases} m_r(v(k) - b_r), & v(k) \geq b_r, \\ 0, & b_l < v(k) < b_r, \\ m_l(v(k) - b_l), & v(k) \leq b_l. \end{cases} \quad (14)$$

其中: $b_r \geq 0$, $b_l \leq 0$, $m_r > 0$, $m_l < 0$ 均为常数; 而且, 折断点 $|b_r| \neq |b_l|$, 倾斜度 $m_r \neq m_l$. 那么

$$\begin{aligned} u(k) &= g(v(k)), \\ v(k) &= g^{-1}(u_d(k)) = g^{-1}(\theta_d; u_d(k)), \end{aligned} \quad (15)$$

即执行器的逆模型可以表示为

$$v(k) = \begin{cases} [u_d(k) + m_r b_r] / m_r, & u_d(k) > 0, \\ 0, & u_d(k) = 0, \\ [u_d(k) + m_l b_l] / m_l, & u_d(k) < 0. \end{cases} \quad (16)$$

死区的实际参数 $\theta_d = (m_r, m_r b_r, m_l, m_l b_l)^T$, 设 $\omega(k) = (-s_r(k)v(k), s_r(k), -s_l(k)v(k), s_l(k))^T$. (17)

其中: 当 $v(k) \geq \hat{b}_r$ 时, $s_r(k) = 1$, 否则, $s_r(k) = 0$; 当 $v(k) \leq \hat{b}_l$ 时, $s_l(k) = 1$, 否则, $s_l(k) = 0$.

这样, $u_d(k)$ 可以用 $-\theta_d^T(k)\omega(k)$ 来表示, 而 $u(k)$ 可以用 $-\hat{\theta}^T(k)\omega(k)$ 来表示, 即

$$u(k) - u_d(k) = [-\hat{\theta}(k) + \theta_d]^T \omega(k). \quad (18)$$

将所建立的执行器的自学习逆模型表示为

$$v(k) = \begin{cases} [u_d(k) + \hat{m}_r \hat{b}_r] / \hat{m}_r, & u_d(k) > 0, \\ 0, & u_d(k) = 0, \\ [u_d(k) + \hat{m}_l \hat{b}_l] / \hat{m}_l, & u_d(k) < 0. \end{cases} \quad (19)$$

这里由于 $\hat{m}_r$, $\hat{m}_l$ 都是需要估计的参数, 因而估计 $\hat{b}_r$, $\hat{b}_l$ 与估计 $\hat{m}_r \hat{b}_r$, $\hat{m}_l \hat{b}_l$ 是一致的.

4.2 在线逆模型补偿算法(Online inverse model compensation)

为了消除执行器非线性特征的影响, 本文由一个在线自学习的逆模型来抵消其非线性特性, 将在线估计逆模型参数表示为 $\hat{\theta}(k)$ (真实模型为 θ_d), 即

$$\hat{\theta}(k) = (\hat{m}_r(k), \hat{m}_r \hat{b}_r(k), \hat{m}_l(k), \hat{m}_l \hat{b}_l(k))^T. \quad (20)$$

设执行器逆模型补偿的误差为

$$\varepsilon(k) = u(k) - u_d(k) = [\theta_d - \hat{\theta}(k)]^T \omega(k). \quad (21)$$

定义自学习逆模型补偿的性能指标函数为

$$J(k) = \frac{1}{2} \varepsilon^2(k). \quad (22)$$

取 $\hat{\theta}(k_0)$ 为初始值, 那么, 自学习算法表示为

$$\begin{aligned} \hat{\theta}(k+1) &= \hat{\theta}(k) + \Delta \hat{\theta}(k), \\ \Delta \hat{\theta}(k) &= -\eta \frac{\partial J(k)}{\partial \hat{\theta}(k)} = -\eta \frac{\partial J(k)}{\partial \varepsilon(k)} \frac{\partial \varepsilon(k)}{\partial \hat{\theta}(k)} = \\ &= -\eta \cdot \varepsilon(k) \cdot [-\omega(k)] = \eta \cdot \varepsilon(k) \cdot \omega(k). \end{aligned} \quad (23)$$

当 $\hat{\theta}(k)$ 不再变化, $\varepsilon(k)$ 趋近于0, 该逆模型能够抵消执行器的“死区”效应, 即消除执行器非线性的影响, 从而可以减小式(7)所示的误差.

5 反馈补偿(Feedback structure)

考虑前面所讨论的AMC与执行器逆模型均是开

环的,系统稳定性不强,实际控制中的不确定性和干扰是不可避免的,因而这里采取一个反馈补偿结构来提高系统稳定性和控制精度,反馈补偿采用图1所示的鲁棒滤波器来实现.由图1所示的系统结构可知

$$y(k+1) = y(k) + f^1(k-1) \cdot \Delta u_c(k) + R + \gamma + \varepsilon. \quad (24)$$

其中: $\Delta u_c(k) = \Delta u(k) + \Delta u_f(k)$, $\Delta u_f(k)$ 为反馈滤波器的增量输出. 利用 $\zeta = z^{-1}(R + \gamma + \varepsilon)$,

$$\Delta u_f(k) = \frac{-F(z)\zeta}{\hat{f}^1(k-1)}, \text{ 则}$$

$$\begin{aligned} y(k+1) &= \\ y(k) &+ f^1(k-1) \cdot \Delta u(k) - \\ &\frac{f^1(k-1)}{\hat{f}^1(k-1)} F(z)\zeta + R + \gamma + \varepsilon = \\ y(k) &+ f^1(k-1) \Delta u(k) - F_1(R + \gamma + \varepsilon), \end{aligned} \quad (25)$$

$$\text{其中 } F_1 = 1 - \frac{f^1(k-1)}{\hat{f}^1(k-1)} z^{-1} F(z).$$

因此,采用合适的滤波器 $F(z)$, 留数项 R 和干扰 γ 在一定程度上可以抵消,从而提高控制精度. ε 则主要由式(23)逐渐消除. 此时,由图1所示的控制系统结构可知合成的控制律的增量形式为

$$\Delta u_c(k) = \frac{y^*(k+1) - y(k)}{\hat{f}^1(k-1)} \alpha(k) - \frac{F(z)\zeta}{\hat{f}^1(k-1)}. \quad (26)$$

其中: 当 $|\Delta u(k)| \leq \delta(k)$ 时, $\alpha(k) = 1$; 当 $|\Delta u(k)| > \delta(k)$ 时, $0 < \alpha(k) < 1$. 此时控制律中包括了逼近模型控制器和反馈补偿两大部分,从而兼有了逼近模型控制与反馈控制的优点.

6 系统稳定性分析(System stability analysis)

定理 1 依据假设1,2,由式(26)所示的控制律,对于所有的时刻 k , 式(7)所示的误差满足一致最终有界性^[8],且最终界 $\lim_{k \rightarrow \infty} |e(k)| \leq \frac{|b_1| + |b_2|}{b_0}$.

其中:

$$\begin{aligned} b_0 &= \beta(k)\alpha(k)[2 - \beta(k)\alpha(k)], \\ b_1 &= [1 - \beta(k)\alpha(k)]\{[1 - \beta(k)\alpha(k)] \cdot \Delta r - \\ &\quad F_1(R + \gamma + \varepsilon)\}, \\ b_2 &= \{[1 - \beta(k)\alpha(k)] \cdot \Delta r - F_1(R + \gamma + \varepsilon)\}, \end{aligned}$$

而 $\beta(k) = \frac{f^1(k-1)}{\hat{f}^1(k-1)}$, 变量 $\Delta r, \alpha(k), R, \gamma, \varepsilon$ 等则分别与假设2和式(24)(25)一致.

证 由式(26)所示的 CAMC 控制律及式(25), 式(7)可表示为

$$e(k+1) =$$

$$\begin{aligned} &y^*(k+1) - y(k) - [\hat{f}^1(k-1) + \xi(k)] \cdot \\ &\frac{y^*(k+1) - y(k)}{\hat{f}^1(k-1)} \alpha(k) - F_1(R + \gamma + \varepsilon). \end{aligned} \quad (27)$$

定义 Lyapunov 函数为 $V(k) = e^2(k)$, 又 $\frac{\hat{f}^1(k-1) + \xi(k)}{\hat{f}^1(k-1)} = \beta(k)$, 那么

$$\begin{aligned} V(k+1) - V(k) &= \\ e^2(k+1) - e^2(k) &= \\ \{y^*(k+1) - y(k) - [y^*(k+1) - \\ y(k)]\beta(k)\alpha(k) - F_1(R + \gamma + \varepsilon)\}^2 - e^2(k) &= \\ \{y^*(k) + \Delta r - y(k) - [y^*(k) + \Delta r - y(k)] \cdot \\ \beta(k)\alpha(k) - F_1(R + \gamma + \varepsilon)\}^2 - e^2(k) &= \\ \{[e(k) + \Delta r][1 - \beta(k)\alpha(k)] - \\ F_1(R + \gamma + \varepsilon)\}^2 - e^2(k) &= \\ \beta(k)\alpha(k)[\beta(k)\alpha(k) - 2]e^2(k) + 2[1 - \beta(k)\alpha(k)] \cdot \\ \{[1 - \beta(k)\alpha(k)] \cdot \Delta r - F_1(R + \gamma + \varepsilon)\}e(k) + \\ \{[1 - \beta(k)\alpha(k)] \cdot \Delta r - F_1(R + \gamma + \varepsilon)\}^2 &= \\ -b_0e^2(k) + 2b_1e(k) + b_2^2. \end{aligned} \quad (28)$$

由假设1和式(25), 可知

$$b_0 = \beta(k)\alpha(k)[2 - \beta(k)\alpha(k)] > 0, \quad (29)$$

而

$$\begin{aligned} 4b_1^2 + 4b_0b_2^2 &= \\ 4[1 - \beta(k)\alpha(k)]^2 \cdot \{[1 - \beta(k)\alpha(k)] \cdot \Delta r - \\ F_1(R + \gamma + \varepsilon)\}^2 + 4\beta(k)\alpha(k)[2 - \\ \beta(k)\alpha(k)]\{[1 - \beta(k)\alpha(k)] \cdot \Delta r - \\ F_1(R + \gamma + \varepsilon)\}^2 &= \\ 4\{[1 - \beta(k)\alpha(k)] \cdot \Delta r - F_1(R + \gamma + \varepsilon)\}^2 &= \\ 4b_2^2 \geq 0. \end{aligned} \quad (30)$$

在式(28)中, 当 $e(k) > \frac{2b_1 + \sqrt{4b_1^2 + 4b_0b_2^2}}{2b_0}$ 或

$$e(k) < \frac{2b_1 - \sqrt{4b_1^2 + 4b_0b_2^2}}{2b_0}, V(k+1) - V(k) < 0.$$

由式(30), $4b_1^2 + 4b_0b_2^2 = 4b_2^2$, 那么可知

$$\text{当 } e(k) > \frac{b_1 + |b_2|}{b_0} \text{ 或 } e(k) < \frac{b_1 - |b_2|}{b_0}, V(k+1) - V(k) < 0.$$

证毕.

此时可知,对于所有的 k , 控制误差满足一致最终有界性,且最终界 $\lim_{k \rightarrow \infty} |e(k)| \leq \frac{|b_1| + |b_2|}{b_0}$.

7 仿真研究(Simulations)

本文将所研究的CAMC系统应用于文[2]中的发电机励磁控制, 采用如下的3阶动态对象模型^[2]:

$$\begin{cases} \dot{\delta} = \omega - \omega_0, \\ \dot{\omega} = \frac{\omega_0 P_m}{H} - \frac{D(\omega - \omega_0)}{H} - \frac{\omega_0 E'_q V_s \sin \delta}{H x'_{d\Sigma}} - \\ \quad \frac{\omega_0 V_s^2}{2H} \left(\frac{x'_d - x_q}{x'_{d\Sigma} x_{q\Sigma}} \right) \sin(2\delta), \\ \dot{E}'_q = \frac{-x_{d\Sigma}}{x'_{d\Sigma} T'_{d0}} E'_q + \frac{(x_d - x'_d) V_s \cos \delta}{x'_{d\Sigma} T'_{d0}} + \frac{V_f}{T'_{d0}}. \end{cases} \quad (31)$$

各个变量的物理含义详见文[2]. 将功角 δ 看作输出 y , 励磁电压 V_f 看作输入 u , 根据文[2]的分析可知

$$y^{(3)} = f(\ddot{y}, \dot{y}, y, u), \quad (32)$$

转换成离散方程式为

$$y(k+1) = f(y(k), y(k-1), y(k-2), u(k)). \quad (33)$$

本文中的对象模型与文[2]一致, 即发电机组及相关参数值为: $x_d = 2.534; x_q = 2.534, x'_d = 0.318; x_T = 0.1; x_L = 1.46; D = 5; H = 8; T'_{d0} = 10; P_{m0} = 0.7$. 根据励磁系统的特点, 确定足够丰富的激励信号作为系统的输入信号. 将幅值范围在0~3之间的控制信号 $u(k)$ 输入到对象中, 根据这些控制输入, 从而产生相应的被控对象输出, 以此建立样本数据对 $\{q(k), u(k)\}$. 在仿真中, SVM训练样本数据对为600, SVM参数为: $\sigma = 1.5, C = 100, \epsilon = 0.02$. 执行器非线性特性如式(14)所示, 参数值为: $b_r = 0.15, b_l = -0.1, m_r = 1.05, m_l = -1.08$. 在线梯度学习算法中, 相关参数为: $\hat{\theta}(k_0) = [1.1, 0.2, -1.1, -0.2]^T$. 鲁棒滤波器选择为 $F(z) = \frac{1-r_1}{1-r_1 z^{-1}}$, 而且 $r_1 = 0.72$.

将本文所研究的CAMC与文[2]中的逼近模型控制器(AMC)及文[9]中的神经网络控制器(NNC)予以了对比. NNC用虚线表示, AMC用细实线表示, 而CAMC用粗实线表示. 在这三种控制器中, CAMC采用了非线性执行器来仿真, 而其他两种控制器仿真中不存在执行器的非线性.

实验1 参考励磁电压变化的阶跃响应. 发电机组在稳态运行, $P_t = 1.0$ (标么值), $Q_t = 0.18$ (标么值). 在 $t = 2$ s时, 给予参考励磁电压的5%阶跃上升, 在 $t = 10$ s时, 再给予参考励磁电压的5%阶跃下降. 图2描述了不同控制器时的暂态响应曲线, 与NNC, AMC相比, CAMC的超调量更小, 振荡量更小.




图2 电压扰动时的响应曲线

Fig. 2 System responses to a step disturbance




图3 短时间短路扰动时的响应曲线

Fig. 3 System responses to short circuit test

实验2 三相短路故障响应.发电机组在上述的稳态运行,在 $t = 2\text{s}$ 时,无穷远母线端发生一个短暂(100ms)的三相短路故障.控制器的性能如图3所示,与NNC、AMC相比,CAMC的超调量更小,振荡量更小,阻尼性能优良.

8 结论(Conclusion)

本文研究了一种补偿逼近模型控制系统,并将执行器的非线性特性也考虑在内.控制器设计中采用逼近模型方法,并通过补偿逆模型来抵消执行器的非线性特征,采用反馈环节来提高系统的鲁棒性特征.文章分析了该控制系统的稳定性特性,针对发动机励磁系统的仿真实验表明了该控制器的较优性能.

参考文献(References):

- [1] MA Y J. New development of direct feedback linearization (DFL) theory[J]. *Journal of Qingdao University*, 1998, 11(1): 68 – 70.
- [2] YUAN X F, WANG Y N, LI S T. A novel excitation controller using support vector machines and approximate models[J]. *Journal of Control Theory and Applications*, 2008, 6(3): 239 – 245.
- [3] YUAN X F, WANG Y N, WU L H. SVM based approximate model control for electronic throttle valve[J]. *IEEE Transactions on Vehicular Technology*, 2008, 57(5): 2747 – 2756.
- [4] YUAN X F, WANG Y N. LS-SVM approximate based inverse controller with uncertainty compensation[J]. *Journal of Dynamic Systems, Measurement and Control*, 2007, 129(6): 845 – 850.
- [5] CORTES C, VAPNIK V. Support-vector networks[J]. *Machine Learning*, 1995, 20(3): 273 – 297.
- [6] VAPNIK V. Universal learning technology: support vector machines[J]. *NEC Journal of Advanced Technology*, 2005, 2(2): 137 – 144.
- [7] ZHOU J, ER M J, ZURADA J M. Adaptive neural network control of uncertain nonlinear systems with nonsmooth actuator nonlinearities[J]. *Neurocomputing*, 2007, 70(4/6): 1062 – 1070.
- [8] SPOONER J T, MAGGIORE M, ORDONEZ R, et al. *Stable Adaptive Control and Estimation for Nonlinear Systems*[M]. New York: Wiley, 2002.
- [9] FAN S, MAO C X, LU J M. Real-time excitation controller using neural networks[J]. *Engineering Intelligent Systems*, 2003, 11(3): 151 – 156.

作者简介:

袁小芳 (1979—), 男, 博士, 目前研究方向为智能控制理论与应用、神经网络、优化计算等, E-mail: yuanxiaof@21cn.com;

孙 炜 (1975—), 男, 博士, 教授, 目前研究方向机器人控制、神经网络控制等, E-mail: david-sun@126.com;

王耀南 (1957—), 男, 博士, 教授, 目前研究方向智能控制理论与应用、模式识别与图像处理等, E-mail: yaonan@hnu.cn;

王 曷 (1986—), 男, 硕士研究生, 主要研究领域为复杂机电系统的建模与控制、智能控制理论与应用等, E-mail: wangbing1986@126.com.