

文章编号: 1001-0920(2007)01-0025-05

基于即时学习的非线性系统优化控制

潘天红, 李少远

(上海交通大学 自动化研究所, 上海 200240)

摘要: 基于数据驱动机制的逆控制是一种非线性系统控制方法, 关键问题在于局部逆控制模型的准确性, 但尚无校验机制来保证其能否产生期望的输出。为此, 提出一种 k -VNN 即时学习算法, 提高了逆控制模型的建模精度。将该算法与性能指标优化策略相结合, 在线修正逆控制模型预估的系统控制量, 可得到系统的一步最优控制量, 实现非线性系统的跟踪控制。为提高控制系统的泛化能力, 提出一种数据库数据更新策略。仿真结果表明了所提出方法的有效性。

关键词: 即时学习; 逆控制; 非线性系统; k -VNN; 留一误差交叉校验

中图分类号: TP273

文献标识码: A

Optimal control for nonlinear systems based on lazy learning

PAN Tian-hong, LI Shao-yuan

(Institute of Automation, Shanghai Jiaotong University, Shanghai 200240, China. Correspondent: LI Shao-yuan, E-mail: syli@sju.edu.cn)

Abstract: The key problem of data-based inverse control is that the accuracy of the inverse model, and no strategy can be adopted to verify expected output. The k -VNN lazy learning algorithm is introduced to improve the accuracy of the inverse control model. And combined with optimal strategy, the one-step ahead optimal output of inverse controller is obtained. In order to improve the generalization ability of inverse controller, a kind of updated strategy is also advanced. Simulated results show the validation of the algorithm.

Key words: Lazy learning; Inverse control; Nonlinear system; k -vector nearest neighbors; Leave-one-out cross validation

1 引言

基于系统数据驱动(Data-driven)的控制方法是近几年出现的一种新的控制算法^[1-5]。该算法在不需系统其他先验知识的条件下, 仅利用非线性系统已存储的大量输入输出数据, 在线学习计算与当前系统状态相匹配的控制量并作用于系统, 便可获得系统所要求的动静态品质。Rhodes^[2]利用此方法对 Lorenz 模型和实际电路进行仿真研究, 取得了较好的跟踪效果。Arif^[3]将其融入迭代学习控制中, 对高速运动机械手进行仿真研究, 并与传统的迭代学习控制结果进行比较, 结果表明, 基于数据驱动的迭代学习控制具有较快的收敛速度和较高的控制精度。孙维等^[5]在此基础上进一步改进了算法的性能, 提出剔除“坏点”数据的策略, 以消除对即时学习算法

的影响, 加快迭代学习算法的收敛速度。上述方法尽管取得了较好的控制效果, 但都是在基于系统已有的数据覆盖所有工况的前提下, 泛化性不强。另外, 所得到的系统当前时刻的控制量 $u(t)$, 没有相应的校验算法来确定其是否能够产生接近理想的输出信号 $r(t+1)$ 。

为解决上述问题, 本文从即时学习(Lazy learning)的思想出发^[4,6], 提出一种系统数据库更新策略, 自适应地添加系统的数据, 提高系统的自学习能力, 以适应系统新的工况要求。另外, 运用 k -VNN(k -Vector Nearest Neighbor)方法^[7]建立系统逆控制模型, 在得到系统当前控制量的同时, 用性能指标优化当前控制量, 在线调整学习过程, 从而得到最优的控制量。最后以最小相位非线性系统的

收稿日期: 2005-10-11; 修回日期: 2005-11-09.

基金项目: 国家自然科学基金项目(60474051, 60534020); 上海市科委重点攻关项目(04DZ11008); 教育部新世纪优秀人才计划项目。

作者简介: 潘天红(1974—), 男, 安徽泾县人, 讲师, 博士生, 从事复杂系统多模型建模与控制的研究; 李少远(1965—), 男, 河北枣强人, 教授, 博士生导师, 从事预测控制、智能控制等研究。

跟踪控制验证了本算法的有效性.

2 数据驱动的逆控制模型算法

考虑如下非线性动态系统:

$$y(t) = f(x(t), u(t)) + (t). \quad (1)$$

式中: $x(t) \in R^d$ 为系统的状态向量, $u(t)$ 为系统的输入, $y(t)$ 为系统的输出, (t) 为系统的噪声, $f(\cdot) \in R^d \times R$ 非线性函数.

关于系统(1)的物理描述未知,但存在 N 组输入输出数据信息 $\{x(i), u(i), y(i)\}_{i=1}^N$. 问题是:在 t 时刻如何选择合适的控制量 $u(t)$ 作用于系统,使系统的输出 $y(t)$ 跟踪期望的轨迹 $r(t)$.

假定系统的逆控制模型为

$$u(t) = f^{-1}(x(t), y(t)) = g(x(t), y(t)). \quad (2)$$

重新排列系统已有的数据信息,如图 1 所示.




图 1 逆控制模型的数据库

数据驱动的逆控制模型算法为:已知系统当前理想的状态信号 $x_q(t)$ 和理想的输出信号 $y_q(t)$,如何利用这些数据来估计理想的控制信号 $u_q(t)$. 通常的方法是^[2,3,5],以局部线性多项式近似当前时刻非线性系统逆控制模型,即

$$\hat{u}(x(t), y(t)) = \Phi^T(t) \phi(t). \quad (3)$$

式中

$$\begin{aligned} \phi(t) &= [1, x(t), y(t)]^T = \\ &= [1, x_1(t), \dots, x_d(t), y(t)]^T, \\ \Phi^T &= [0, \phi_1, \dots, \phi_d, \phi_{d+1}]. \end{aligned}$$

构造系统的信息向量 $\phi_q(t) = [x_q(t), y_q(t)]^T$,以信息间的距离(Euclidean 距离)为指标,在数据库中选择 k 组最接近 $\phi_q(t)$ 的信息向量. 线性回归这些信息向量,可得到当前系统的逆控制模型与系统理想的控制信号 $u(t)$,即

$$\hat{u} = [(W)^T(W)^{-1}(W)^T W]^{-1} W^T u. \quad (4)$$

这里: $W = [\Phi(1), \Phi(2), \dots, \Phi(k)]$; $W = \text{diag}(w_i)$, 其 对 角 元 素 w_i 由 信 息 向 量 $\Phi(i)$ 与 $\phi_q(t)$ 的 Euclidean 距离决定,通常由下式计算得到^[1,8,9]:

$$w_i = \sqrt{K(d, h)} = \sqrt{\exp(-d/h^2)}, \quad (5a)$$

$$d = \sqrt{(\phi_q(t) - \Phi(i))^T (\phi_q(t) - \Phi(i))}, \quad (5b)$$

则当前时刻系统的理想控制输出信号为

$$\hat{u}_q(t) = \hat{u}^T \phi_q(t). \quad (6)$$

3 基于即时学习的一步最优控制

通过上述数据驱动的学习算法建立的逆控制

模型,可得到系统的理想的控制信号,将其作用于系统,可实现非线性系统的跟踪控制^[2]. 然而,由式(6)得到的控制信号 $\hat{u}_q(t)$,没有相应的算法检验其是否能够产生接近于设定的轨迹 $r(t+1)$. 文献[1]分析了这种算法的弊端,由于系统是非线性的,其逆映射对应的输出值 $\hat{u}_q(t)$ 与实际系统的理想控制信号 $u_q(t)$ 之间往往存在较大的建模误差,单独使用逆控制模型,不能使系统跟踪期望的轨迹^[1]. 为此,从系统信息向量的相似性指标出发,提出了 k -VNN 方法,以最大程度地减少逆控制模型建模误差;同时采用性能指标优化的方法,在线修正当前时刻系统的控制量,得到系统最优控制量.

3.1 即时学习算法

3.1.1 信息的相似性准则

传统的即时学习算法都采用 k -NN 方法选择用于局部建模的信息向量^[4,6,9],然而这种方法不能完全表征信息的相似性. 为说明问题,考虑二维空间的 3 个信息向量,如图 2 所示. 图中 $d(\phi_q, \phi_1) = d(\phi_q, \phi_2)$ (d 为 Euclidean 距离,同式(5)),但 $\theta_1 < \theta_2$. 也就是说,表征 ϕ_q 的特性时,向量 ϕ_1 更优于 ϕ_2 . 另外, $\theta_2 > 90^\circ$,即向量 ϕ_2 与 ϕ_q 反向,不能表征信息向量 ϕ_q 的当前特性,用它建模会影响精度.




图 2 向量相似性示意图

为了增加模型的准确性,本文提出向量近邻的概念,构造 k -VNN 方法^[7]. 即不仅仅以信息向量 Euclidean 距离最短为信息选择准则,而是综合考虑信息向量的距离与角度信息^[10],形成新的信息选择准则

$$D(\phi_q, \phi_i) = \sqrt{e^{-d(\phi_q, \phi_i)} + (1 - \cos(\theta(\phi_q, \phi_i)))}. \quad (7)$$

这里

$$d(\phi_q, \phi_i) = \sqrt{(\phi_q - \phi_i)^T (\phi_q - \phi_i)},$$

$$\cos(\theta(\phi_q, \phi_i)) = \frac{\phi_q^T \phi_i}{\|\phi_q\| \|\phi_i\|},$$

为加权因子, $0 \leq \theta \leq \pi$.

从式(7)可以看出,加权选择准则 $D(\phi_q, \phi_i)$ 直接反映了 ϕ_q 与 ϕ_i 的靠近程度. 这是因为两个信息向

量越靠近, $d(\phi_q, \phi_i)$ 越小, $\sqrt{e^{-d(\phi_q, \phi_i)}}$ 越大, 且其夹角也越小, $\cos(\phi_q, \phi_i)$ 也越大, 从而整个 $D(\phi_q, \phi_i)$ 也就越大.

定义 1 向量 k 近邻 (k -Vector Nearest Neighbors). 已知系统存在信息数据集 $DB: \{\phi_i, y_i\}_{i=1}^N$, 给定查询向量 ϕ_q 和向量的最近邻个数 k , 以式 (7) 为搜索准则, 得到 ϕ_q 最相似数据集 $VNN_q(k)$, 满足

$$\left. \begin{aligned} VNN_q(k) \subseteq DB; \\ \forall \phi_p \in VNN_q(k), \\ \forall \phi_s \in DB - VNN_q(k), \end{aligned} \right\} \begin{aligned} D(\phi_p, \phi_q) > \\ D(\phi_s, \phi_q). \end{aligned} \quad (8)$$

这样, 在已有的系统信息中, 可用 k -VNN 方法在 ϕ_q 附近构造建模学习集, 具体描述如下:

- 1) 当 ϕ_i 与 ϕ_q 的夹角较大时, 即 $\cos(\phi_i, \phi_q) < 0$, 则认为此信息向量偏离当前工作点, 不利于系统局部建模, 放弃选用此信息构造学习集.
- 2) 当 $\cos(\phi_i, \phi_q) \geq 0$ 时, 以 $D(\phi_i, \phi_q)$ 大小为准, 选择 $D(\phi_i, \phi_q)$ 最大的 k 组数据信息, 按降序排列构造学习集.

即时学习算法学习集的大小 (即 k 值) 也影响模型的精度和算法的速度, 目前尚没有较好的方法来事先确定, 只能事后估计^[9]. 因此, 在建模开始时, 可依据先验知识确定近邻 k 的变化范围 $[k_m, k_M]$. 确定当前工作点 ϕ_q 的模型最少需要 k_m 个系统数据, 最大需要 k_M 个系统数据.

3.1.2 即时学习算法

以系统的实际输出与模型输出偏差的加权平方和最小为性能指标, 构造准则函数

$$J(\hat{\phi}_q) = \sum_{i=1}^k (y_i - \hat{y}_i(\hat{\phi}_q))^2 D(\phi_i, \hat{\phi}_q), \quad (9)$$

引入 $D(\phi_i, \hat{\phi}_q)$ 的目的是为了便于考虑所选信息向量的可信度, 本文认为最靠近 ϕ_q 的信息向量最能反映 ϕ_q 的特性, 其权值最大, 依此类推.

极小化 $J(\hat{\phi}_q)$ 可以得到系统当前工作点的局部模型 $\hat{\phi}_q$. 这样, 当前系统的即时输出为

$$\hat{y}_q = \hat{\phi}_q^T \Lambda. \quad (10)$$

为了减小计算量, 在计算近邻 $k+1$ 的局部模型 $\hat{\phi}_{k+1}$ 时, 直接利用近邻 k 的模型值 $\hat{\phi}_k$, 采用递归最小二乘算法

$$\begin{cases} \hat{\phi}_{k+1} = \hat{\phi}_k^T P_k \phi_{k+1} + 1 / D_{k+1}, \\ P_{k+1} = P_k \phi_{k+1} \phi_{k+1}^T, \\ e_{k+1} = y_{k+1} - \hat{\phi}_{k+1}^T \Lambda_k, \\ \Lambda_{k+1} = \Lambda_k + \phi_{k+1} e_{k+1}, \\ P_{k+1} = P_k - \frac{P_k \phi_{k+1} \phi_{k+1}^T P_k}{\phi_{k+1}^T P_k \phi_{k+1} + 1}, \end{cases} \quad (11)$$

得到近邻 $k+1$ 的模型 $\hat{\phi}_{k+1}$. 同时, 也可以得到近邻 k

+ 1 的留一交叉误差值 (Leave-one-out cross validation)^[6,9]

$$e_{k+1,j}^{loo} = y_j - \hat{\phi}_{k+1}^j \Lambda_{k+1} = \frac{y_j - \hat{\phi}_{k+1}^j \Lambda_{k+1}}{1 - \phi_{k+1}^j \phi_{k+1}^j}, \quad j = 1, \dots, k+1. \quad (12)$$

式中: $\hat{\phi}_{k+1}^j$ 表示在 $k+1$ 组信息中用去掉第 j 个信息向量所得到的局部模型; $e_{k+1,j}^{loo}$ 表示实际值 y_j 与模型 $\hat{\phi}_{k+1}^j$ 得到的预测值之间的误差. 这样, 可以得到近邻 $k+1$ 的留一交叉误差集 ($k+1$ 个 $e_{k+1,j}^{loo}$)

$$e^{loo}(k+1) = \{e_{k+1,j}^{loo}\}_{j=1}^{k+1}, \quad (13)$$

均方和这些留一交叉误差

$$MSE^{loo}(k+1) = \frac{\sum_{j=1}^{k+1} D(\phi_j, \phi_q) (e_{k+1,j}^{loo})^2}{D(\phi_j, \phi_q)}. \quad (14)$$

式中: 加权因子 $D(\phi_j, \phi_q)$ 的大小, 直接反映每个信息向量的留一交叉误差对均方和误差“贡献”的大小. 越靠近 ϕ_q 的信息向量, 其留一交叉误差的“贡献”越大, 反之越小. 此时, 如果

$$MSE^{loo}(k+1) > MSE^{loo}(k), \quad k+1 \in [k_m, k_M], \quad (15)$$

则认为模型“变差”, 停止回归计算, 并以模型 $\hat{\phi}_k$ 作为系统当前时刻的最佳模型; 否则, 按式 (12) 从学习集中选取新的信息向量, 继续迭代, 直到 $k = k_M$ 为止. 这样, 可以及时判断局部模型的优劣, 得到当前时刻系统最佳的局部线性模型. 而且 MSE^{loo} 也可以作为递归最小二乘算法 (11) 的中止条件, 及时退出递归过程.

3.2 一步最优控制算法

假定系统下一步输出即可跟踪设定的轨迹, 即 $y_q(t) = r(t+1)$. 如前所述, 利用系统的逆控制模型, 在 $\phi_q^{inv} = [1, x_q(t), r(t+1)]^T$ 处, 用即时学习算法可得到系统当前时刻的控制量

$$\hat{u}(t) = f^{-1}(x_q(t), y_q(t)) = g_{LL}(x_q(t), r(t+1)). \quad (16)$$

此时, $\hat{u}(t)$ 并不一定是系统的最优值. 同样运用 k -VNN 即时学习建模方法估计系统在 $\phi_q = [1, x_q(t), \hat{u}(t)]^T$ 的估计输出值

$$\hat{y}(t+1) = f_{LL}(x_d(t), u(t)). \quad (17)$$

设优化问题的目标函数为

$$J = (r(t+1) - \hat{y}_{LL}(t+1))^2 + \lambda (u(t) - u(t-1))^2, \quad (18)$$

式中 λ 为控制增量的惩罚系数.

此时, 如果 $\min J$ 最小, 则以当前 $\hat{u}(t)$ 作用于系

统;否则,继续按式(17)和(18)优化当前系统的控制信号,直到 J 取得最小值。

3.3 系统数据库更新策略

如前所述,数据驱动的学习算法都要求系统已有数据库覆盖所有工况,这使得该学习算法受到极大的限制。为使系统适应于新的工况条件,即时添加新的数据信息,同时避免系统数据的重叠,本文提出如下更新策略:

在利用式(7)得到系统相似信息向量的同时,计算 k_m 个最大的 $[D(\phi_q, \phi_i)]_{i=1}^{k_m}$ 的平均值

$$D_{km} = \left[\max_{i=1}^{k_m} (D(\phi_q, \phi_i)) \right] / k_m. \quad (19)$$

若 $D_{km} < \delta$ (δ 为给定的阈值),则认为此时信息 ϕ_q 为系统新的数据,即时添加到数据库中;否则,认为原数据库中含有这个信息,建模之后丢弃 ϕ_q 。

3.4 算法步骤

基于即时学习的一步最优控制算法步骤可概括如下:

Step1: 在 t 时刻,得到系统的逆信息向量 ϕ_q^v ;

Step2: 采用 k -VNN 即时学习建模算法,得到 ϕ_q^v 点的系统局部逆控制模型的估计值 $\hat{\alpha}(t)$;

Step3: 构造系统的信息向量 ϕ_q ,利用 k -VNN 即时学习算法得到系统输出的估计值 $\hat{y}(k+1)$;

Step4: 计算式(18)是否最小,若取得最小值,则转 Step5,否则转 Step3。

Step5: $u^{opt} = \hat{\alpha}(t)$,作用于系统;

Step6: 用式(19)计算 D_{km} ,若 $D_{km} < \delta$,则更新学习集。

4 仿真实验

考虑文献[6]的 SISO 非线性系统,用如下差分方程表示:

$$\begin{aligned} y(t+1) = & [y(t)y(t-1)y(t-2)(y(t-2)- \\ & 1)u(t-1) + u(t)] / [1 + y^2(t-1) + \\ & y^2(t-2)] + \alpha(t). \end{aligned} \quad (20)$$

文献[6]分析了该非线性函数是一非最小相位系统,基于数据驱动的逆控制模型学习算法不能对该系统进行跟踪控制。

设系统可由输入输出模型描述为

$$y(t+1) = f(y(t), y(t-1), y(t-2), u(t), u(t-1)). \quad (21)$$

若系统的设定轨迹 $r(t)$ 为:幅值在 $[-0.7, +0.7]$ 之间,周期为 80 倍系统采样周期的方波信号,以 $\phi(t) = [y(t), y(t-1), y(t-2), u(t), u(t-1)]^T$ 为信息向量,则系统的逆控制模型的信息向量

为 $\phi^{nv}(t) = [y(t), y(t-1), y(t-2), y(t+1), u(t-1)]^T$ 。采用本文提出的一步最优算法,即时学习参数为 $\alpha = 0.85, k = [15, 80], \delta = 0.06, \beta = 0.9$ 。考虑以下 3 种情况:

1) 固定数据集的一步最优控制 ($\delta(t) = 0$)。系统运行之前,用 $[-2, +2]$ 之间的零均值单位协方差随机信号作用于系统^[6],得到 5 000 组输入输出数据,并将这 5 000 组数据作为系统数据集。系统仿真结果如图 3 所示。由图 3 可知,因为使用初始系统的激励信号覆盖系统的工况,所以系统投入运行即可跟踪期望的轨迹。




图3 固定数据集的方波跟踪曲线

2) 自动更新数据库的一步最优控制 ($\delta(t) = 0$)。系统投入运行之前,其数据集为空集。根据本文提出的即时更新数据库策略,在线更新系统的数据集,其仿真结果如图 4 所示。由图 4 可知,系统开始运行的第 1 个周期 (1 ~ 80),由于系统数据集没有相似的模态,跟踪性能较差;随着系统的运行,跟踪性能越来越好,稳态误差为 0。




图4 即时更新数据集的方波跟踪曲线

3) 系统的干扰情况 ($\delta(t) = 0$)。为验证本文控制算法的干扰抑制能力,在系统输出端添加 $\alpha(t)$




图5 有扰动的方波跟踪曲线

$[-0.175, +0.175]$, $\sigma = 0.1$ 的白噪声扰动^[9]. 系统的跟踪情况如图 5 所示. 由图 5 可知, 系统能较好地跟踪设定轨迹.

5 结 论

本文从信息向量的相似性角度, 提出了 k -VNN 即时学习算法, 该算法能够提高局部建模的精度. 将该算法与数据驱动(Data-driven)的逆控制方法相结合, 在得到系统控制量的同时, 用性能指标最优策略在线修正系统控制量, 可得到当前的最优控制量. 将其作用于系统, 可实现系统跟踪控制.

为提高系统的泛化能力, 同时避免系统数据库过于庞大, 提出了数据库更新策略, 以适应系统新的工况要求. 仿真结果表明了所提出方法的有效性.

参考文献(References)

- [1] Atkeson C G, Moore A W, Schaal S. Locally weighted learning for control [J]. *Artificial Intelligence Review*, 1997, 11(1): 75-113.
- [2] Rhodes C, Morari M, Tsimring L S, et al. Data-based control trajectory planning for nonlinear systems [J]. *Physical Review E*, 1997, 56(3): 2398-2406.
- [3] Arif M, Ishihara T, Inooka H. Incorporation of experience in iterative learning controllers using locally weighted learning [J]. *Automatica*, 2001, 6(37): 881-888.
- [4] Bertolissi E, Birattari M, Bontempi G, et al. Data-driven techniques for direct adaptive control: The lazy and the fuzzy approaches [J]. *Fuzzy Sets and Systems*, 2002, 128(1): 3-14.
- [5] 孙维, 王伟, 朱瑞军. 即时学习算法在非线性系统迭代学习控制中的应用[J]. *控制与决策*, 2003, 18(3): 263-266.
(Sun W, Wang W, Zhu R J. Iterative learning control for nonlinear system using lazy learning method [J]. *Control and Decision*, 2003, 18(3): 263-266.)
- [6] Bontempi G, Birattari M, Bersini H. Lazy learning for local modeling and control design [J]. *Int J Control*, 1999, 72(7/8): 643-658.
- [7] 潘天红, 李少远, 王昕. 基于即时学习的非线性系统多模型建模方法[C]. 第二十四届中国控制会议论文集. 广州: 华南理工大学出版社, 2005: 268-273.
(Pan T H, Li S Y, Wang X. A multi-model modeling approach to nonlinear systems based on lazy learning [C]. *Proc of the 24th Chinese Control Conf.* Guangzhou: Publishing Company of South China University of Technology, 2005: 268-273.)
- [8] 李柠, 李少远, 席裕庚. 基于 LPF 算法的多模型建模方法[J]. *控制与决策*, 2002, 17(1): 11-14.
(Li N, Li S Y, Xi Y G. Multi-model modeling method based on LPF algorithm [J]. *Control and Decision*, 2002, 17(1): 11-14.)
- [9] Bontempi G. Local learning techniques for modeling prediction and control [D]. Bruxelles: IRIDIA-Universit  Libre de Bruxelles, 1999.
- [10] Cheng Cheng, Chiu Mir-Sen. A new data-based methodology for nonlinear process modeling [J]. *Chemical Engineering Science*, 2004, 13(59): 2801-2810.
- [1] Tipsuwan Y, Chow M Y. Control methodologies in networked control systems [J]. *Control Engineering Practice*, 2003, 11(10): 1099-1111.
- [2] Hokayem P F, Abdallah C T. Inherent issues in networked control systems: A survey [C]. *Proc American Control Conf.* Boston, 2004: 4897-4902.
- [3] Nilsson J, Bernhardsson B, Wittenmark B. Stochastic analysis and control of real time systems with random time delays[J]. *Automatica*, 1998, 34(1): 57-64.
- [4] Hu S S, Zhu Q X. Stochastic optimal control and analysis of stability of networked control systems with long delay[J]. *Automatica*, 2003, 39(11): 1877-1884.
- [5] Li S B, Wang Z, Sun Y X. Delay-dependent controller design for networked control systems with long time delays: An iterative LMI method[C]. *Proc of the 5th World Congress on Intelligent Control and Automation.* Hangzhou, 2004:1338-1342.
- [6] Zhang W, Branicky M S, Phillips S M. Stability of networked control systems [J]. *IEEE Control Systems Magazine*, 2001, 21(1): 84-99.
- [7] 樊卫华, 蔡骅, 吴晓蓓, 等. 具有延时和数据包丢失的网络控制系统的稳定性[J]. *南京理工大学学报*, 2004, 28(5): 465-468.
(Fan W H, Cai H, Wu X B, et al. Stability of networked control systems with time delay and data packet dropout [J]. *J of Nanjing University of Science and Technology*, 2004, 28(5): 465-468.)
- [8] Wang Y, Xie L, De Souza C E. Robust control of a class uncertain nonlinear systems [J]. *Systems and Control Letter*, 1992, 19(3): 139-149.
- [9] Boyd S, Ghaoui L E, Feron E, et al. *Linear matrix inequalities in system and control theory* [M]. Philadelphia:SIAM, 1994.
- [10] Hassibi A, Boyd S P, How J P. Control of asynchronous dynamical systems with rate constraints on events[C]. *Proc IEEE Conf Decision and Control*, Phoenix, 1999: 1345-1351.

(上接第 24 页)