

改进的非线性离散系统自适应数据驱动控制

董娜^{1†}, 吴爱国¹, 陈增强²

(1. 天津大学 天津市过程检测与控制重点实验室; 电气与自动化工程学院, 天津 300072;

2. 南开大学 信息技术科学学院 自动化系, 天津 300071)

摘要: 基于同步扰动随机近似的算法, 控制器选取为一个函数逼近器, 并在这里被确定为神经网络. 控制算法中使用了自适应的参数估计, 明显改善了控制性能, 同时也给出了相应的收敛性分析. 最后, 新型的控制算法被应用到了解决非线性离散系统的跟踪控制问题中, 并通过仿真比较结果, 充分验证了这种自适应数据驱动控制策略的可行性和有效性.

关键词: 自适应数据驱动控制; 同步扰动随机近似; 神经网络; 非线性离散系统

中图分类号: TP13 **文献标识码:** A

Improved adaptive data-driven control for discrete nonlinear systems

DONG Na^{1†}, WU Ai-guo¹, CHEN Zeng-qiang²

(1. Tianjin Key Laboratory of Process Measurement and Control; School of Electrical Engineering and Automation, Tianjin University, Tianjin 300072, China;

2. Department of Automation, College of Information Technical Science, Nankai University, Tianjin 300071, China)

Abstract: The controller is designed based on the simultaneous perturbation stochastic approximation (SPSA) method and is constructed through the use of a function approximator (FA) which is actually a neural network. In the control algorithm, the adaptive parameter estimator is employed for improving the control performances. The proposed control strategy is proved to be convergent and is applied to solve nonlinear tracking problems for discrete-time nonlinear systems. The feasibility and effectiveness of the proposed adaptive data-driven control strategy is well validated through simulation comparison tests.

Key words: adaptive data-driven control; simultaneous perturbation stochastic approximation; neural networks; discrete nonlinear systems

1 引言(Introduction)

20世纪中叶以来, 现代控制理论和方法取得了空前的发展, 并且产生了诸如自适应控制、系统辨识、鲁棒控制、最优控制、随机系统理论等新的领域与分支, 这些新型的控制理论和方法已经在工业控制、航空航天以及生物化学等诸多方面取得了显著的成就. 然而, 当前的控制理论与应用的研究仍面临着巨大的挑战. 在很多的对系统信息不十分明确的领域中, 自适应控制算法得到了广泛的应用, 但目前大多数自适应控制的理论成果均依赖于被控系统精确的数学模型, 因而普遍存在对受控系统数学模型结构的依赖性和未建模动态的两个问题; 另外, 在实际的控制过程中, 需要假设系统的方程已知, 但是在复杂的物理、社会经济或是生物系统中, 系统的参数以及系统的方程形式通常都为未知的, 这就使得建立受控系统的数学模型,

尤其是建立复杂非线性系统的数学模型, 到目前为止仍然是一个非常困难的问题. 因此, 已有的自适应控制方法往往在实际应用中难以得到所需的控制律. 因此, 如何仅依赖于系统的输入输出信息, 设计不依赖于受控对象动力学特性的控制方法, 具有极其重要的理论与现实意义. 国内外已经有一些学者开始在此领域展开研究, 并且取得了一定的成果^[1-3].

近年来, 基于经典比例-积分-微分(proportion integration differentiation, PID)控制的新型控制策略以及与人工神经网络相结合的自适应控制算法^[4]有了长足的发展, 虽然这些算法都不需要事先建立系统的数学模型, 但它们都存在各自的制约因素. 本文中提出了一种基于同步扰动随机近似^[5]的自适应数据驱动控制策略, 采用函数逼近器作为控制器, 从而最终实现了不依赖于受控系统模型的控制器的设计.

收稿日期: 2012-09-21; 收修改稿日期: 2013-04-11.

[†]通信作者. E-mail: dongna@tju.edu.cn; Tel.: +86 22-27406272.

基金项目: 天津市应用基础与前沿技术研究计划资助项目(13JCQNJC03600); 国家自然科学基金资助项目(61174094); 天津大学自主创新研究基金资助项目(2013XQ-0041).

神经网络是一种被广泛使用的近似工具^[6-7],它能够对数据进行有效地学习,其平行式结构也使得它便于对多维非线性函数进行逼近.神经网络也是实现动态系统辨识和控制的一种有效手段,它能够对未知系统的输入-输出以及控制率进行准确的映射^[8-9].目前,很多基于神经网络,径向基网络,小波网络等的网络结构已被用来作为黑箱非线性动力学模型^[10-11].函数逼近的问题也是求解微分方程的核心问题,神经网络能够提供泛化性能很好的可微封闭解析形式的解,因此得到了广泛的应用^[12].本文中,作为控制器的函数逼近器也被选取为神经网络.

2 基于同步扰动随机近似的控制算法(Simultaneous perturbation stochastic approximation based control strategy)

基于同步扰动随机近似(simultaneous perturbation stochastic approximation, SPSA)^[5]的控制方法首先由Spall于1993年提出^[1].这种算法的特点在于它不需要事先建立被控系统的数学模型.

首先考虑一个状态空间不连续的系统:

$$\begin{cases} x_{k+1} = \varphi_k(x_k, u_k, \omega_k), \\ y_k = h_k(x_k, v_k), \end{cases} \quad k = 0, 1, 2, \dots, \quad (1)$$

其中: $\varphi(\cdot)$ 和 $h_k(\cdot)$ 分别为决定系统动态性能的未知非线性系统和度量过程, u_k 是 $k+1$ 时刻系统输入的控制信号, ω_k 和 v_k 为噪声.基于包含度量 y_k 和控制 u_{k-1} 的信息,控制的目的是找到可以使得某个与下一个度量函数 y_{k+1} 相关的损失函数最小的控制信号 u_k .通常情况下,这个损失函数用来比较 y_{k+1} 和目标值 t_{k+1} 之间的差值.

这里,使用一个函数模拟器,来产生控制信号 u_k .考虑一个随时间变化结构固定的函数模拟器,但允许函数模拟器的内在参数进行更新.由于过去的信息将被用作控制输入,这种固定的结构要求 u_k 只基于一个固定数量的度量函数和控制量(相对于在时间 k 所用到的所有可用信息).控制过程中,需要估计产生 u_k 的函数模拟器以及参数向量 θ_k .

定义控制性能指标如下:

$$J_k(\theta_k) = E[(y(\theta_k, k+1) - y_d(k+1))^2]. \quad (2)$$

控制器设计的目的是对每个时刻 k 寻找一个最优的控制参数 θ_k^* ,从而使得控制性能指标函数值最小.根据控制性能指标函数的定义可知,若要让它最小,需要求得导数 $\frac{\partial y(\theta_k, k+1)}{\partial \theta_k}$,但是,这在不知道被控对象的模型信息的情况下无法求取,也就致使传统的优化方法不能使用.而基于SPSA的控制方法则能够有效地解决这种未知被控对象模型信息的最优化问题,它采用同步扰动随机近似的算法来估计参数向

量 θ_k :

$$\hat{\theta}_k = \hat{\theta}_{k-1} - a_k \hat{g}_k(\hat{\theta}_{k-1}), \quad (3)$$

其中: a_k 为标量系数,通常选取为一个固定的常数($a_k = c$)^[10], $\hat{\theta}_k$ 为本次迭代得到的估计值. $g_k(\hat{\theta}_{k-1})$ 为梯度, $\hat{g}_k(\hat{\theta}_{k-1})$ 为 $g_k(\hat{\theta}_{k-1})$ 的同步扰动估计值,考虑一般的随机估计的框架形式,扰动度量 $L(\cdot)$ 是可知的.算法设计时,令

$$\begin{cases} \phi_k^{(+)} = L(\hat{\theta}_k + c_k \Delta_k) + \varepsilon_k^{(+)}; \\ \phi_k^{(-)} = L(\hat{\theta}_k - c_k \Delta_k) + \varepsilon_k^{(-)}, \end{cases} \quad (4)$$

其中: $\varepsilon_k^{(+)}$ 和 $\varepsilon_k^{(-)}$ 代表度量的噪声项,并满足

$$\begin{cases} E(\varepsilon_k^{(+)} - \varepsilon_k^{(-)} | F_k, \Delta_k) = 0, \text{ a.s. } \forall k, \\ F_k \equiv \{\hat{\theta}_0, \hat{\theta}_1, \dots, \hat{\theta}_k\}, \end{cases} \quad (5)$$

其第 p 个分量的计算公式为

$$\hat{g}_{kp}(\hat{\theta}_{k-1}) = \frac{\phi_k^{(+)} - \phi_k^{(-)}}{2c_k \Delta_{kp}}, \quad (6)$$

其中: $p = 1, 2, \dots, P$, P 为控制参数的个数.这里 $\Delta_k = [\Delta_{k1}, \Delta_{k2}, \dots, \Delta_{kP}]^T$ 为一个随机产生的向量,通常 Δ_{kP} 服从独立有界对称分布, c_k 为标量系数,一般选取为趋于的序列或等于常数.

从上述介绍中可看出,这种基于SPSA的控制算法,每次迭代中只需要进行两次闭环实验,利用闭环实验的测量数据就可以估计得到 $g_k(\hat{\theta}_{k-1})$ 的估计值 $\hat{g}_k(\hat{\theta}_{k-1})$,整个过程中不需要被控对象的模型信息.这种控制算法的控制结构框图如图1所示.

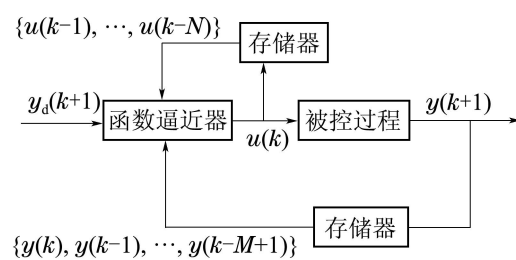


图1 基于SPSA的控制算法结构框图

Fig. 1 Scheme of the SPSA based control strategy

3 自适应数据驱动控制算法(Adaptive data driven control)

3.1 改进的自适应控制算法(Improved adaptive control algorithm)

在这一部分,提出了改进的自适应数据驱动控制算法,并给出了相应的收敛性证明.用作控制器的函数逼近器在这里被选取为神经网络,它的网络层数以及各层的网络结点数是固定的,而连接权值也就是这里的控制参数 θ_k 是可调的.

神经网络的输入为当前时刻之前固定长度时间窗内的控制量和输出量,以及下一时刻,亦即 $k+1$ 时刻

的期望输出神经网络以(7)式为输入, $u(k)$ 为输出.

$$I = [y(k), y(k-1), \dots, y(k-M+1), u(k-1), u(k-2), \dots, u(k-N), y_d(k+1)], \quad (7)$$

其中: $y(k)$ 为时刻 k 的被控对象输出, $u(k)$ 为时刻 k 的被控对象的控制输入, $y_d(k+1)$ 为 $k+1$ 时刻被控对象的期望输出, M 和 N 分别为数据的时间窗长度. 控制的目的是要找到最优的控制参数 θ_k^* 从而使目标函数 J 最小. 控制器的整体结构如图2所示.




图 2 控制器整体结构框图

Fig. 2 The whole structure of the controller

在这里所讲的数据驱动控制算法中, 控制参数 θ_k 由下式及式(3)计算得到:

$$\hat{g}_{kl}(\hat{\theta}_{k-1}) = \frac{\hat{J}_k^+ - \hat{J}_k^-}{2c_k \Delta_{kl}}, \quad (8)$$

其中: \hat{J}_k^\pm 为 $J_k(\hat{\theta}_{k-1} \pm c_k \Delta_k)$ 的估计值, 利用测量值 y_{k+1}^\pm 和 u_{k+1}^\pm 计算得到 $\hat{J}_k^\pm = (y_{k+1}^\pm - y_d(k+1))^2$, y_{k+1}^\pm 为被控对象的控制输入等于 u_{k+1}^\pm 时的输出测量值, u_{k+1}^\pm 为控制参数 $\theta_k = \hat{\theta}_{k-1} \pm c_k \Delta_k$ 时产生的控制量.

文献[13]中指出, 控制器参数 a_k 的选取对于算法性能的发挥是十分重要的. a_k 选取过小会导致误差减小速度缓慢, 而选取过大则会导致系统的不稳定. 因此, 应该在算法运行初期选用相对较小的 a_k , 并随着算法的运行逐步增大其取值, 直到系统能够在保证稳定运行的前提下达到一定的收敛速度.

原有基于SPSA的控制算法通常选取 a_k 为一常数, 这样往往不能够兼顾到系统误差的收敛速度和系统的稳定性, 因此, 为改善算法的性能, 本文提出了一种 a_k 自适应调节的算法, 控制器参数 a_k 定义为

$$a_k = \frac{\alpha}{1 + \lambda/k^2}, \quad (9)$$

其中 α 和 λ 为标量系数, 算法的收敛性证明在下一小节中给出.

3.2 算法的收敛性分析(Convergence analysis of the algorithm)

在这一部分, 给出了一个命题, 确定了能够保证参数 $\hat{\theta}_k$ 准确收敛到 θ^* 的条件. 误差项的定义为

$$e_k(\hat{\theta}_k) = \hat{g}_k(\hat{\theta}_k) - E(\hat{g}_k(\hat{\theta}_k)|\hat{\theta}_k). \quad (10)$$

这样, 式(2)可以就改写为

$$\hat{\theta}_{k+1} = \hat{\theta}_k - a_k[\hat{g}_k(\hat{\theta}_k) + b_k(\hat{\theta}_k) + e_k(\hat{\theta}_k)]. \quad (11)$$

首先, 引入一些假设条件:

I) 考虑 $k \geq K$, $K < \infty$ 假设对于每个 k , Δ_{ki} ($i = 1, 2, \dots, p$)都为独立同分布的, 并对称分布于两侧, 满足 $|\Delta_{ki}| \leq \alpha_0$ 且 $E|\Delta_{ki}^{-1}| \leq \alpha_1$. 对于几乎所有 $\hat{\theta}_k$, 假设在 $\hat{\theta}_k$ 附近的所有 θ , $L^{(3)}(\theta) \equiv \frac{\partial^3 L}{\partial \theta^3}$ 存在且连续(L 定义为某个可导的代价函数), 并满足 $|L^{(3)}_{i_1 i_2 i_3}(\theta)| \leq \alpha_2$.

II) $c_k > 0$, $\forall k; k \rightarrow \infty$ 时, $c_k \rightarrow 0$; 并且

$$\sum_{k=0}^{\infty} \left(\frac{a_k}{c_k}\right)^2 < \infty.$$

III) 对 $\alpha_0, \alpha_1, \alpha_2$ 和 $\forall k$, 都有

$$E[\varepsilon_k^\pm]^2 \leq \alpha_0, \quad E[L(\hat{\theta}_k \pm c_k \Delta_k)]^2 \leq \alpha_1,$$

且 $[\Delta_{kp}^{-2}] \leq \alpha_2$ ($p = 1, 2, \dots, P$).

IV) $\|\hat{\theta}_k\| < \infty$ a.s. $\forall k$.

V) θ^* 为微分方程 $\frac{dx(t)}{dt} = -g(x)$ 渐进稳定的解.

VI) 令 $D(\theta^*) = \{x_0 : \lim_{t \rightarrow \infty} x(t|t_0) = \theta^*\}$, 其中: $x(t|t_0)$ 代表2中的微分方程的解(x_0 为初始条件, $D(\theta^*)$ 为吸引域), 则存在一个数组 $S \subseteq D(\theta^*)$, 使得 $\hat{\theta}_k \in S$ 对于几乎所有的采样点成立.

命题 如果假设条件I)–VI)成立, 则当 $k \rightarrow \infty$ 时, 对于所有 $\omega \in \Omega$, $\hat{\theta}_k \rightarrow \theta^*$ 成立.

证 基于文献[14]引理2.2.1和定理2.3.11的理论, 可以得到: 若给定II), IV)–VI)如果

i) $\|b_k(\hat{\theta}_k)\| < \infty, \forall k, b_k(\hat{\theta}_k) \rightarrow 0$.

ii) 对于任意 $\eta > 0$,

$$\lim_{n \rightarrow \infty} P(\sup_{m \geq k} \|\sum_{i=k}^m a_i e_i(\hat{\theta}_i)\| \geq \eta) = 0$$

成立, 则命题成立.

由文献[5]可知:

$$b_k(\hat{\theta}_k) \equiv E(\hat{g}_k(\hat{\theta}_k) - g_k(\hat{\theta}_k)|\hat{\theta}_k) = o(c_k^2)(c_k \rightarrow 0), \quad (12)$$

所以由假设条件II)和式(16)就可以得到i)成立.

接下来证明ii): 由于这里的控制参量 a_k 定义为

$$a_k = \frac{\alpha}{1 + \lambda/k^2},$$

且 $\{\sum_{i=k}^m a_i e_i\}_{m \geq k}$ 为一个鞅序列, 所以从文献[15]可得

$$P(\sup_{m \geq k} \|\sum_{i=k}^m a_i e_i(\hat{\theta}_i)\| \geq \eta) \leq$$

$$\eta^{-2} E\|\sum_{i=k}^{\infty} a_i e_i(\hat{\theta}_i)\|^2 =$$

$$\eta^{-2} \sum_{i=k}^{\infty} a_i^2 E\|e_i(\hat{\theta}_i)\|^2 =$$

$$\eta^{-2} \sum_{i=k}^{\infty} \frac{\alpha^2 \mathbb{E} \|e_i(\hat{\theta})\|^2}{(1 + \lambda/i^2)^2}. \quad (13)$$

再根据式(4)(6)的定义

$$\hat{g}_k(\hat{\theta}_k) = \frac{\phi_k^{(+)} - \phi_k^{(-)}}{2c_k \Delta_{kp}} = \frac{L(\hat{\theta}_k + c_k \Delta_k) + \varepsilon_k^{(+)} - (L(\hat{\theta}_k - c_k \Delta_k) + \varepsilon_k^{(-)})}{2c_k \Delta_{kp}}, \quad (14)$$

则

$$\mathbb{E}[\hat{g}_k(\hat{\theta}_k)]^2 = \mathbb{E}\left[\frac{L(\hat{\theta}_k + c_k \Delta_k) - L(\hat{\theta}_k - c_k \Delta_k) + \varepsilon_k^{(+)} - \varepsilon_k^{(-)}}{2c_k \Delta_{kp}}\right]^2. \quad (15)$$

由假设条件III, 可知:

$$\mathbb{E}[\varepsilon_k^{(\pm)}]^2 \leq \alpha_0, \quad \mathbb{E}[L(\hat{\theta}_k \pm c_k \Delta_k)]^2 \leq \alpha_1, \\ [\Delta_{kp}^{-2}] \leq \alpha_2, \quad p = 1, 2, \dots, P,$$

这样就能够得到

$$\mathbb{E}[\hat{g}_k(\hat{\theta}_k)]^2 = \frac{1}{4} \mathbb{E}[L(\hat{\theta}_k + c_k \Delta_k) - L(\hat{\theta}_k - c_k \Delta_k) + \varepsilon_k^{(+)} - \varepsilon_k^{(-)}]^2 \cdot \mathbb{E}[\Delta_{kp}^{-2}] \cdot c_k^{-2} \leq 2(\alpha_1 + \alpha_0)\alpha_2 c_k^{-2}. \quad (16)$$

又由于 $e_k(\hat{\theta}_k) = \hat{g}_k(\hat{\theta}_k) - \mathbb{E}(\hat{g}_k(\hat{\theta}_k)|\hat{\theta}_k)$, 所以得

$$\|e_k(\hat{\theta}_k)\|^2 = \sum_{p=1}^P (\hat{g}_{kp}(\hat{\theta}_{kp}) - \mathbb{E}(\hat{g}_{kp}(\hat{\theta}_{kp})|\hat{\theta}_{kp}))^2. \quad (17)$$

已知

$$\mathbb{E}(e_i^T e_j) = \mathbb{E}(e_i^T \mathbb{E}(e_j|\hat{\theta}_j)) = 0, \quad \forall i < j,$$

现在就可以得到对于任意的 $p \in \{1, 2, \dots, P\}$, 都有

$$\mathbb{E}\|e_k(\hat{\theta}_k)\|^2 \leq P \cdot \mathbb{E}[\hat{g}_k(\hat{\theta}_k)]^2 \leq 2P(\alpha_1 + \alpha_0)\alpha_2 c_k^{-2}. \quad (18)$$

最后, 通过式(13), 假设条件II)和ii), 可得命题成立. 证毕.

4 仿真分析(Simulation and analyses)

为了有效地验证文中所提出的自适应数据驱动控制算法的有效性, 这里引入了两个典型非线性系统^[16], 并对它们的跟踪控制问题进行仿真实验. 基于SPSA的无模型控制方法^[1]被引入进来用作仿真比较.

这里的目标函数定义为 $J_k(\theta_k) = \mathbb{E}[e_k^2(\theta_k)]$, 其中 e_k 为跟踪误差, $e_k(\theta_k) = y_{dk} - y_k$.

首先, 引入以下非线性系统来做仿真分析:

$$y(k+1) = \frac{y(k)y(k-1)(y(k) - 2.5)}{1 + y^2(k) + y^2(k-1)} + u(k), \quad (19)$$

使用新型的自适应数据驱动控制算法对其进行控制,

这里的控制器设定为一个有两个隐含层的多层神经网络, 并针对系统(19)选取了 $N_{3,3,2,1}$ 的神经网络结构. 依据收敛原则^[17], 选取了递减的参数

$$c_k = \frac{0.15}{k^{0.101}},$$

并依照所提出的自适应数据驱动控制策略, a_k 选取为

$$a_k = \frac{0.005}{1 + 0.05/k^2}.$$

进行了50次独立的仿真实验, 并且对输出误差Err进行了评估:

$$\text{Err} = \frac{\sum_{k=1}^S (y(k) - y_d(k))^2}{S}, \quad (20)$$

其中 S 为运行步数.

给定信号选取为幅值为6的正弦信号, 使用新型自适应数据驱动控制策略, 单次运行系统的跟踪结果如图3所示, 相应的控制信号在图4中给出. 作为仿真比较, 使用基于SPSA的无模型控制算法对系统进行同样的跟踪控制, a_k 选取为固定值 $a_k = 0.05$, 控制结果如图5所示, 相应的输入控制信号在图6中给出. 对于两种不同的控制算法, 分别统计了系统独立运行50次的平均输出误差, 比较结果在表1中给出.




图3 新型自适应数据驱动控制算法对系统(19)的跟踪控制结果

Fig. 3 Performance of the adaptive data driven control strategy on plant (19)




图4 输入控制信号

Fig. 4 The corresponding control input




图 5 基于SPSA的无模型控制算法对系统(19)的跟踪控制结果

Fig. 5 Performance of the SPSA based model-free control method on plant (19)




图 6 输入控制信号

Fig. 6 The corresponding control input

表 1 对非线性系统(19)的50次仿真结果比较

Table 2 Comparison results on (19) out of 50 runs

控制方法	误差均值	方差
新型自适应数据驱动控制算法	12.8371	5.82
基于SPSA的无模型控制算法	50.8064	37.1425

通过表1仿真比较结果可以明显地看出,与基于SPSA的无模型控制算法相比,新型的自适应数据驱动控制策略可以得到更好的控制跟踪效果,并且能够取得更小的跟踪误差.此外,由于基于SPSA的控制算法在每步运行的控制信号的计算中,都有随机扰动的存在,并且,控制器结构和控制器参数的选取也都会影响到系统的稳定性,因此,在控制跟踪过程中就可能会出现异常尖峰的情况(如图5),通过以上的仿真比较也可以看出新型的自适应控制算法在此方面要明显地优于原有的基于SPSA的控制算法,从而进一步说明了新型控制策略的有效性.

为了进一步验证新型算法的控制性能,引入了另外的一个典型非线性系统的跟踪控制问题:

$$y(k+1) = \frac{y(k)}{1+y^2(k)} + u(k) + 5u(k-1). \quad (21)$$

给定幅值为1的方波信号,选取结构为 $N_{3,3,3,1}$ 的神经网络作为其控制器,控制器参数 a_k, c_k 的选取与系统(19)相同.使用新型自适应数据驱动控制策略,单次运行系统的跟踪结果如图7所示,相应的控制信号在图8中给出.作为仿真比较,使用基于SPSA的无模型控制算法对系统进行同样的跟踪控制,控制结果如图9所示,相应的输入控制信号在图10中给出.

对于两种不同的控制算法,分别统计了系统独立运行50次的平均输出误差,比较结果在表2中给出.




图 7 新型自适应数据驱动控制算法对系统(21)的跟踪控制结果

Fig. 7 Performance of the adaptive data driven control strategy on plant (21)




图 8 输入控制信号

Fig. 8 The corresponding control input




图 9 基于SPSA的无模型控制算法对系统(21)的跟踪控制结果

Fig. 9 Performance of the SPSA based model-free control method on plant (21)




图 10 输入控制信号

Fig. 10 The corresponding control input

表 2 对非线性系统(21)的50次仿真结果比较
Table 2 Comparison results on plant (21) out of 50 runs

控制方法	误差均值	方差
新型自适应数据驱动控制算法	4.3×10^{-3}	9.42×10^{-2}
基于SPSA的无模型控制算法	0.5466	0.7359

通过表2的仿真结果,可以明显地看出文中所提出的自适应数据驱动控制策略具有更好的控制性能,并且能够取得更小的跟踪误差.在两个非线性系统的仿真测试中,新型的自适应数据驱动控制策略都取得了更加精确的跟踪结果,尤其是在第2个非线性系统的仿真实验中,原有的基于SPSA的控制算法并不能够实现对方波信号的准确跟踪控制,而文中所提出的自适应数据驱动控制策略则取得了良好的跟踪结果,并且跟踪误差很小,从而有力地验证了新型自适应数据驱动控策略的有效性.

5 结论(Conclusions)

本文提出了一种改进的自适应数据驱动控制策略,并给出了其收敛性分析.新型的控制策略被应用到非线性系统的跟踪控制问题中,引入了基于SPSA的无模型控制算法在两个典型的非线性系统上做了仿真比较实验,并通过仿真结果充分地验证了新型控制策略的有效性.

在未来的研究工作中,作者将继续深入研究如何选取最优的控制器参数 α 和 λ ,并对自适应控制参数 a_k 的设计法则做进一步的推导和论证.并且,将通过与更多类似的无模型控制算法的比较,来更好地对文中的自适应数据驱动控制策略进行客观的评价和深入的分析,以进一步改善控制算法的性能.另外,将会与实际的工业生产相结合,针对控制过程中随机扰动的存在对实际系统所能造成的影响,以及相应的解决策略展开更加深入的研究.如何选取函数逼近器的结构(如神经网络的隐含层数及节点数)是另一亟待解决的问题,笔者也将继续在这一方向上进行深入的研究.

参考文献(References):

- [1] SPALL J C, CRISTION J A. Model-free control of general discrete-time systems [C] // *Proceedings of the 32nd IEEE Conference on Decision and Control*. San Antonio, Texas: [s.n.], 1993: 2792 – 2797.
- [2] HOU Z S, HUANG W H. The model-free learning adaptive control of a class of nonlinear discrete-time systems [J]. *Control Theory & Applications*, 1998, 15(6): 893 – 899.
- [3] HOU Z S, JIN S T. A novel data-driven control approach for a class of discrete-time nonlinear systems [J]. *IEEE T-CST*, 2011, 19(6): 1549 – 1558.
- [4] 贾鹤鸣, 张利军, 齐雪, 等. 基于神经网络的水下机器人三维航迹跟踪控制 [J]. *控制理论与应用*, 2012, 29(7): 877 – 883. (JIA Heming, ZHANG Lijun, QI Xue, et al. Three-dimensional path tracking control for autonomous underwater vehicle based on neural network [J]. *Control Theory & Applications*, 2012, 29(7): 877 – 883.)
- [5] SPALL J C. Multivariate stochastic approximation using a simultaneous perturbation gradient approximation [J]. *IEEE Transactions on Automatic Control*, 1992, 37(3): 332 – 341.
- [6] WERBOS P J. *Handbook of intelligent control* [S]. WHITE D A, SOFGE D A, Eds. New York: Van Nostrand, 1992: 65 – 86.
- [7] SUTTON R S, BARTO A G. Reinforcement learning [M] // *Essays in Control*. Cambridge, MA: MIT Press, 1998.
- [8] NARENDRA K S, PARTHASARANTHY K. Identification and control of dynamical systems using neural networks [J]. *IEEE Transactions on Neural Network*, 1990, 1(1): 4 – 27.
- [9] HUNT K J, SBARBARO D, ZBIKOWSKI R. Neural networks for control systems: a survey [J]. *Automatica*, 1992, 28(6): 1083 – 1112.
- [10] JUDITSKY A, HHALMARSSON H, BENVENISTE A, et al. Non-linear black-box models in system identification: mathematical foundations [J]. *Automatica*, 1995, 31(12): 1691 – 1724.
- [11] MOFEED T R, MATTIA F, ABDULADHEM A A, et al. Nonlinear model identification for artemia population motion [J]. *Nonlinear Dynamics*, 2012, 69(4): 2237 – 2243.
- [12] LAGARIS I E, LIKAS A, FOTIADIS DI. Artificial neural networks for solving ordinary and partial differential equations [J]. *IEEE Transactions on Neural Network*, 1998, 9(5): 987 – 995.
- [13] SPALL J C, CRISTION J A. Model-free control of nonlinear stochastic systems with discrete-time measurements [J]. *IEEE Transactions on Automatic Control*, 1998, 43(9): 1198 – 1210.
- [14] KUSHNER H J, CLARK D S. Stochastic approximation methods for constrained and unconstrained systems [M] // *Essays in Control*. New York: Springer-Verlag, 1978.
- [15] DOOB J L. Stochastic processes [M] // *Essays in Control*. New York: Wiley, 1953.
- [16] LI X, CHEN Z Q, YUAN Z Z. Simple recurrent neural network-based adaptive predictive control for nonlinear systems [J]. *Asian Journal of Control*, 2002, 4(2): 231 – 239.
- [17] SPALL J C, CRISTION J A. Model-free control of nonlinear stochastic systems with discrete-time measurements [J]. *IEEE Transactions on Automatic Control*, 1998, 43(9): 1198 – 1210.

作者简介:

董娜 (1983–), 女, 讲师, 主要研究方向为非线性控制、神经网络控制、优化算法等, E-mail: dongna@tju.edu.cn;

吴爱国 (1954–), 男, 教授, 博士生导师, 研究领域为电气及液压运动、建筑环境与设备、航空飞行器为对象的非线性控制、先进控制理论, E-mail: agwu@tju.edu.cn;

陈增强 (1964–), 男, 教授, 博士生导师, 研究领域为智能预测控制、混沌系统与复杂动态网络、多智能体系统控制, E-mail: chenzq@nankai.edu.cn.