

基于数据驱动的非线性网络系统自适应迭代学习控制

刘红霞, 史玄玄, 沈谋全

引用本文:

刘红霞, 史玄玄, 沈谋全. 基于数据驱动的非线性网络系统自适应迭代学习控制[J]. 控制与决策, 2021, 36(6): 1523–1528.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2019.1182>

## 您可能感兴趣的其他文章

Articles you may be interested in

### 输入约束不确定系统的点对点迭代学习控制与优化

Point-to-point iterative learning control and optimization for uncertain systems with constrained input

控制与决策. 2021, 36(6): 1435–1441 <https://doi.org/10.13195/j.kzyjc.2019.0908>

### 基于T-S模糊模型的多时滞非线性网络切换控制系统非脆弱 $H_\infty$ 控制

Non-fragile  $H_\infty$  control for multi-delay nonlinear network switching control system based on T-S model

控制与决策. 2021, 36(5): 1087–1094 <https://doi.org/10.13195/j.kzyjc.2019.1098>

### 有限频域线性重复过程的动态迭代学习控制

Dynamic iterative learning control for linear repetitive processes over finite frequency ranges

控制与决策. 2021, 36(3): 599–608 <https://doi.org/10.13195/j.kzyjc.2019.0873>

### 事件触发机制下分布时滞网络化控制系统 $H_\infty$ 故障检测

Event-triggered  $H_\infty$  fault detection for networked control systems with distributed delays

控制与决策. 2020, 35(12): 3059–3065 <https://doi.org/10.13195/j.kzyjc.2019.0456>

### 基于强化学习的小型无人直升机有限时间收敛控制设计

Finite time control based on reinforcement learning for a small-size unmanned helicopter

控制与决策. 2020, 35(11): 2646–2652 <https://doi.org/10.13195/j.kzyjc.2019.0328>

# 基于数据驱动的非线性网络系统自适应迭代学习控制

刘红霞, 史玄玄<sup>†</sup>, 沈谋全

(南京工业大学电气工程与控制科学学院, 南京 211800)

**摘要:** 针对非线性网络控制系统中测量数据的量化及随机丢包问题, 给出一种基于数据驱动的自适应迭代学习控制算法。该算法能够保证系统在数据量化、随机丢包以及不确定迭代学习长度等因素的影响下, 经过有限次迭代后输出轨迹跟踪误差收敛到零; 借助伪偏导线性化方法, 将非线性系统转换为线形时变系统形式; 在线性系统框架下利用前一批次的系统输出信息更新自适应学习增益。与传统迭代学习控制算法不同的是, 该算法无需预知迭代长度的先验信息和控制系统模型信息。最后通过Matlab仿真实验验证所提出算法的有效性。

**关键词:** 数据驱动设计; 数据量化; 迭代学习控制; 随机丢包; 非线性系统控制; 随机迭代长度

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2019.1182

开放科学(资源服务)标识码(OSID):

引用格式: 刘红霞, 史玄玄, 沈谋全. 基于数据驱动的非线性网络系统自适应迭代学习控制 [J]. 控制与决策, 2021, 36(6): 1523-1528.



## Data driven adaptive learning control of nonlinear network system

LIU Hong-xia, SHI Xuan-xuan<sup>†</sup>, SHEN Mou-quan

(College of Electrical Engineering and Control Science, Nanjing Tech University, Nanjing 211800, China)

**Abstract:** Aiming at the quantization of measurement data and random packet loss problems in nonlinear network control systems, this paper presents a data-driven based adaptive iterative learning control algorithm. This algorithm can ensure that the output tracking error can converge to zero after a limited number of iterations, although the system suffers from factors such as data quantification, random packet loss, and uncertainties. Resorting to a pseudo partial derivative based linearization method, the nonlinear system is converted into a linear time-varying system form. Under the framework of linear systems, the adaptive learning gain is updated by the previous batch outputs. Different from the traditional iterative learning control algorithm, the proposed one has no need to predict a priori iteration length and the control system model. Finally, the effectiveness of the proposed algorithm is verified by simulations.

**Keywords:** data driven design; data quantization; iterative learning control; packet dropout; nonlinear systems control; random iteration length

## 0 引言

迭代学习控制(ILC)是一类智能控制, 其在轨迹跟踪上具有良好的控制效果, 因此受到人们越来越多的关注与研究<sup>[1-3]</sup>。值得注意的是, 在上述研究中系统每批次的迭代长度均相同, 即任务执行时间都是相同的。然而, 在实际应用中各批次的迭代长度可能是随机变化的, 如类人机器人步态控制问题<sup>[4]</sup>等。在此类问题上传统的迭代学习控制不再适用, 因此, ILC随机迭代长度问题受到人们的关注<sup>[4-7]</sup>。文献[4]针对随机迭代长度的线性ILC系统, 引入最大通长误差的概念, 采用Lifting表示法建立了满足系统单调收敛的充

要条件; 文献[5]将P型迭代学习控制应用于线性系统, 在不预先知道迭代长度的先验概率信息的条件下给出了系统均方收敛的条件。然而, 文献[4-5]仅讨论了线性系统的随机迭代长度问题。实际上, 几乎所有的控制系统都含有非线性, 因此很难得到其精确的系统模型。在上述研究的基础上, 文献[6]针对连续非线性系统提出了一种改进的迭代移动平均算子方法, 并同时应用于仿射和非仿射的非线性系统; 文献[7]针对具有随机迭代长度的非线性系统提出了一种新的无模型自适应ILC控制方案, 仅利用系统的输入输出数据构建自适应迭代学习控制律。

收稿日期: 2019-08-19; 修回日期: 2019-11-14.

基金项目: 国家自然科学基金项目(61403189).

责任编辑: 关新平.

<sup>†</sup>通讯作者. E-mail: shenmouquan@njtech.edu.cn.

另一方面,由于网络控制系统具有灵活性好、低成本、安装简单等优点,在批次过程中得到了广泛的应用<sup>[8]</sup>. 然而,网络的稳定性及带宽限制也给控制带来了新的挑战,如数据随机丢包问题、数据量化问题、网络延时问题等<sup>[9-10]</sup>. 如果上述问题得不到妥善处理,则很难获得理想控制性能. 针对数据量化和随机丢包问题,文献[12-13]利用2D系统理论将原系统模型转换成二维Roesser模型,并结合鲁棒控制的方法来解决迭代学习控制数据随机丢包问题;文献[14]应用Lifting方法给出跟踪误差收敛的条件,并给出存在数据丢失时鲁棒控制器的设计方法;文献[15]针对一类离散时间系统提出了几种不同的量化ILC方案,并基于超向量公式给出了收敛条件;文献[16]考虑了时变拓扑数字网络的量化迭代学习问题,其中在编码和解码过程中考虑了量化通信,并给出了实现一致性跟踪的充分条件. 尽管这些结果促进了对迭代学习控制的研究,但应指出的是,它们只能用于具有固定迭代长度的迭代学习控制. 虽然文献[7]提出了一种无模型自适应迭代长度随机变化的ILC,但量化数据和随机丢包的影响没有得到很好的处理.

在上述研究成果的基础上,本文给出一种新的无模型自适应迭代学习控制(MFAILC)算法,用于非仿射非线性网络系统控制问题. 通过与已有结果的比较,本文的主要贡献如下:1) 本文仅利用量化后且存在随机丢包的系统输入输出数据来设计迭代学习控制器,不需要知道系统具体的模型信息;2) 本设计中迭代批次长度可变;3) 本设计中各批次初始状态可以不相同,并能保证系统在有限次迭代后的跟踪误差的期望趋于零.

## 1 问题描述

本文研究如下非仿射的非线性网络控制系统:

$$y(t+1, k) = f(\alpha(t, k)q(y(t, k)), u(t, k)). \quad (1)$$

其中: $k$ 为迭代参数; $t \in [0, 1, \dots, N_t]$ 为系统采样点, $N_t$ 为随机数,表示批次长度; $u(k, t) \in R^1$ 和 $y(k, t) \in R^1$ 分别为系统的输入和输出; $f(\cdot)$ 是非仿射函数; $q(\cdot)$ 和 $\alpha(t, k)$ 分别为对数量化器和丢包参数. 系统框图如图1所示.

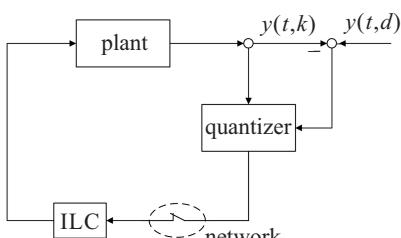


图1 网络控制系统框图

定义 $N_d$ 为期望批次长度. 在实际中 $N_t$ 可能比期望批次长度 $N_d$ 小或比期望批次长度大. 当 $N_t < N_d$ 时,系统在时间区间 $[N_t + 1, N_d]$ 上的输出为0;而当 $N_t > N_d$ 时,则丢弃 $N_t$ 大于 $N_d$ 的部分,因为多余的部分对迭代学习控制不起作用.

假定 $N_1$ 为各批次过程中的最小批次长度,于是系统的实际批次长度落在区间 $\{N_1, \dots, N_d\}$ 内,即在时间区间 $[0, N_t]$ 内可以测得系统输出. 为了更清楚地描述迭代长度的随机性,定义一满足伯努利二项分布的随机数 $\gamma(t, k), t \in [0, N_d]$ . 事件 $\gamma(t, k)$ 表示可以获得 $t$ 时刻的系统输出,其概率用 $p(t)$ 表示,即 $E\{\gamma(t, k)\} = p(t)$ . 接着令 $N_t = N_1 + l$ ,  $\text{Prob}\{N_t\} = p_l$ , 其中 $l \in \{1, \dots, N_d - N_1\}, 0 \leq p_l < 1$ , 可得

$$E\{\gamma(t, k)\} = p(t) = \begin{cases} 1, & t \in [0, N_1]; \\ \sum_{l=t-N_1}^{N_d-N_1} p_l, & t \in [N_1 + 1, N_t]. \end{cases}$$

本文的随机网络丢包现象用随机数 $\alpha(t, k)$ 表示,其满足伯努利二项分布.  $\alpha(t, k) = 0$ 表示数据丢失,相反 $\alpha(t, k) = 1$ 表示数据被成功传输. 由此可得下式:

$$\text{Prob}\{\alpha(t, k) = 1\} = E\{\alpha(t, k)\} = \alpha, \quad (2)$$

其中 $0 \leq \alpha \leq 1$ 为已知参数.

为减小数据传输所占用的网络带宽资源,采用对数量化器对测量数据进行量化,如下式所示:

$$q(v) = \begin{cases} x_j, & \frac{1}{1+\delta}x_j \leq v \leq \frac{1}{1-\delta}x_j; \\ 0, & v = 0; \\ -q(-v), & v < 0. \end{cases}$$

其中: $\delta = (1-\theta)/(1+\theta), 0 < \theta < 1$ .

可以看出量化器 $q(\cdot)$ 是对称的. 应用扇区有界方法得到

$$q(v) = (1 + \Sigma)v, \quad (3)$$

其中 $|\Sigma| \leq \delta$ .

不失一般性,给出以下假设.

**假设1** 函数 $f(\cdot)$ 对输入 $u(t, k)$ 的偏导是连续的.

**假设2** 对于所有 $t \in [0, 1, \dots, N_t]$ 和 $k = 1, 2, \dots$ , 当 $\Delta u(t, k) \neq 0$ 时,系统(1)在迭代方向的函数满足一般的李普希茨条件,即

$$|\Delta y(t+1, k)| \leq b |\Delta u(t, k)|.$$

其中

$$\Delta y(t+1, k) = y(t+1, k) - y(t, k),$$

$$\Delta u(t, k) = u(t, k) - u(t, k-1),$$

$b > 0$  是已知常数.

在上述两个假设的基础上, 引入以下引理.

**引理1<sup>[17]</sup>** 满足假设1和假设2的非线性系统(1), 如果  $\Delta u(t, k) \neq 0$ , 则存在有界时变参数  $\Phi(t, k)$  将非线性系统转换成以下的线性系统形式:

$$\Delta y(t+1, k) = \Phi(t, k)\Delta u(t, k). \quad (4)$$

本文的研究目的如下:

对于给定的理想输出轨迹  $y_d(t), t \in [0, 1, \dots, N_d]$ , 仅利用系统的输入输出信息设计控制器, 使得非线性系统(1)在网络丢包和数据量化下的输出轨迹误差期望  $E\{e(t, k)\} = E\{y_d(t) - y(t, k)\}$  在有限次的迭代后趋于零.

## 2 主要结果

定义

$$e^*(t, k) = \alpha(t, k)q(\gamma(t, k)e(t, k)), \quad (5)$$

$$\begin{aligned} \Delta y^*(t, k) = \\ \alpha(t, k)q(y(t, k)) - \alpha(t, k-1)q(y(t, k-1)), \end{aligned} \quad (6)$$

PPD更新项可表示为

$$\begin{aligned} \xi^*(t, k) = \\ \gamma(t, k)(\Delta y^*(t, k) - \hat{\Phi}(t-1, k)\Delta u(t-1, k)). \end{aligned} \quad (7)$$

给出如下MFAILC算法:

$$\begin{aligned} u(t, k) = \\ u(t, k-1) + \frac{\rho\hat{\Phi}(t, k)}{\lambda + |\hat{\Phi}(t, k)|^2}e^*(t+1, k-1), \\ \hat{\Phi}(t, k) = \\ \hat{\Phi}(t, k-1) + \frac{\eta\Delta u(t, k-1)}{\mu + |\Delta u(t, k-1)|^2}\xi^*(t+1, k-1), \end{aligned} \quad (8)$$

当  $|\hat{\Phi}(t, k)| \leq \varepsilon$  或者  $|\Delta u(t, k-1)| \leq \varepsilon$  或者  $\text{sign}(\hat{\Phi}(t, k)) \neq \text{sign}(\hat{\Phi}(t, 1))$  时,  $\hat{\Phi}(t, k) = \hat{\Phi}(t, 1)$ . 其中:  $\mu > 0$  为比重参数,  $\eta$  为步长参数,  $\varepsilon > 0$  为很小的常数,  $\hat{\Phi}(t, 1)$  为  $\hat{\Phi}(t, k)$  的初值.

**假设3** 在整个批次过程中  $\hat{\Phi}$  的符号不变, 为方便起见, 本文假设  $\hat{\Phi}(t, k) > 0$ .

下面给出本文的主要定理.

**定理1** 若非线性系统(1)满足以上假设1~假设3, 则 MFAILC 算法(8) 中存在  $\lambda > \lambda_{\min} > 0$ , 使得系统在  $t \in [1, 2, \dots, N_t]$  上输出误差期望  $\lim_{k \rightarrow \infty} E\{e(t, k)\} \rightarrow 0$ .

**证明** 首先给出  $\hat{\Phi}(t, k)$  有界的证明.

当  $|\hat{\Phi}(t, k)| \leq \varepsilon$  或者  $|\Delta u(t, k-1)| \leq \varepsilon$  或者  $\text{sign}(\hat{\Phi}(t, k)) \neq \text{sign}(\hat{\Phi}(t, k-1))$  时,  $\hat{\Phi}(t, k) = \hat{\Phi}(t, 1)$ ,

显然能够得到  $\hat{\Phi}(t, k)$  是有界的.

此外, 根据扇区有界的方法(3), 可得

$$\Delta y^*(t, k) = (1 + \Sigma)(1 + \zeta(t, k))\Delta y(t, k) + \Theta(t, k).$$

其中

$$\begin{aligned} \zeta(t, k) &= \alpha(t, k) - 1, \\ \Theta(t, k) &= (1 + \Sigma)(\zeta(t, k) - \zeta(t, k-1))y(t, k-1). \end{aligned}$$

结合  $\Delta y^*(t, k)$  与式(7)得到

$$\begin{aligned} \xi^*(t, k) &= \gamma(t, k)(1 + \Sigma)(1 + \zeta(t, k)) \times \\ &\quad \Phi(t-1, k)\Delta u(t-1, k) - \\ &\quad \gamma(t, k)\hat{\Phi}(t-1, k)\Delta u(t-1, k) + \\ &\quad \gamma(t, k)\Theta(t, k). \end{aligned} \quad (9)$$

将式(9)代入(8), 得

$$\begin{aligned} \hat{\Phi}(t, k) &= \left(1 - \frac{\gamma(t+1, k-1)\eta\Delta u^2(t, k-1)}{\mu + |\Delta u(t, k-1)|^2}\right) \times \\ &\quad \hat{\Phi}(t, k-1) + \gamma(t+1, k-1) \times \\ &\quad (1 + \Sigma)(1 + \zeta(t+1, k-1)) \times \\ &\quad \frac{\eta\Delta u^2(t, k-1)}{\mu + |\Delta u(t, k-1)|^2}\Phi(t, k-1) + \Theta_2(t, k), \end{aligned} \quad (10)$$

其中

$$\Theta_2(t, k) = \frac{\gamma(t+1, k-1)\eta\Delta u(t, k-1)\Theta(t+1, k-1)}{\mu + |\Delta u(t, k-1)|^2}.$$

选择  $\eta \in (0, 1), \mu > 0$ , 可得  $\eta\Delta u^2(t, k-1) < \Delta u^2(t, k-1) < \mu + \Delta u^2(t, k-1)$ , 即存在  $d_2 < 1$  满足

$$0 < 1 - \frac{\gamma(t+1, k-1)\eta\Delta u^2(t, k-1)}{\mu + |\Delta u(t, k-1)|^2} \leq d_2. \quad (11)$$

由  $\zeta(t+1, k-1) = \alpha(t+1, k-1) - 1, \alpha(t+1, k-1) \in \{0, 1\}$ , 得

$$|1 + \zeta(t+1, k-1)| < 1. \quad (12)$$

又因为  $|1 + \Sigma| < 1 + \delta < 2$ , 所以结合式(11)和(12), 式(10)可写为

$$\begin{aligned} |\hat{\Phi}(t, k)| &\leq \\ d_2|\hat{\Phi}(t, k-1)| + 2|\Phi(t, k-1)| + |\Theta_2(t, k)|. \end{aligned} \quad (13)$$

由  $E\{\zeta(t, k) - \zeta(t, k-1)\} = 0$  得  $E\{\Theta_2(t, k)\} = E\{\Theta(t+1, k-1)\} = E\{\Theta(t, k)\} = 0$ . 所以结合式(11)对(13)两边取期望, 得

$$\begin{aligned} |E\{\hat{\Phi}(t, k)\}| &\leq \\ d_2|E\{\hat{\Phi}(t, k-1)\}| + 2b &\leq \dots \leq \end{aligned}$$

$$d_2^{k-1} |E\{\hat{\Phi}(t, 1)\}| + \frac{2b}{1-d_2},$$

因此,  $E\{\hat{\Phi}(t, k)\}$  对于所有的  $t \in \{0, 1, \dots, N_t\}$  有界.

接下来给出  $\lim_{k \rightarrow \infty} E\{e(t, k)\} \rightarrow 0$  的证明. 结合式(8), 式(4)可转换成

$$\begin{aligned} y(t+1, k) - y(t+1, k-1) = \\ \frac{\rho\hat{\Phi}(t, k)\Phi(t, k)}{\lambda + |\hat{\Phi}(t, k)|^2} e^*(t+1, k-1), \end{aligned} \quad (14)$$

于是系统误差可表示为

$$\begin{aligned} e(t+1, k) = & \left(1 - (1+\Sigma)\gamma(t+1, k-1) \times \right. \\ & \left. \alpha(t+1, k-1) \frac{\rho\hat{\Phi}(t, k)\Phi(t, k)}{\lambda + |\hat{\Phi}(t, k)|^2}\right) \times \\ & e(t+1, k-1). \end{aligned} \quad (15)$$

因为  $E\{\Phi(t, k)\}$  和  $E\{\hat{\Phi}(t, k)\}$  都是有界的, 且  $\lambda + |E\{\hat{\Phi}(t, k)\}|^2 \geq 2\sqrt{\lambda}|\hat{\Phi}(t, k)|$ , 所以存在  $\rho$  和  $\lambda > \lambda_{\min} > 0$  满足下式:

$$\begin{aligned} 0 < \frac{E\{\rho\Phi(t, k)\hat{\Phi}(t, k)\}}{\lambda + |E\{\hat{\Phi}(t, k)\}|^2} \leqslant \frac{\rho b \hat{\Phi}(t, k)}{2\sqrt{\lambda}|\hat{\Phi}(t, k)|} < \\ \frac{\rho b}{2\sqrt{\lambda_{\min}}} < 1. \end{aligned} \quad (16)$$

又因为  $\Sigma \in (0, 1)$ ,  $E\{\gamma(t+1, k-1)\} \in (0, 1)$ ,  $E\{\alpha(t+1, k-1)\} \in (0, 1)$ , 所以存在  $d_3 \in (0, 1)$  满足

$$\left| E\left\{ 1 - (1+\Sigma)\gamma(t+1, k-1)\alpha(t+1, k-1) \times \frac{\rho\hat{\Phi}(t, k)\Phi(t, k)}{\lambda + |\hat{\Phi}(t, k)|^2} \right\} \right| \leq d_3 < 1. \quad (17)$$

因此, 式(15)可写为

$$\begin{aligned} |E\{e(t+1, k)\}| \leq \\ d_3 |E\{e(t+1, k-1)\}| \leq \dots \leq \\ d_3^{k-1} |E\{e(t+1, 1)\}|. \end{aligned}$$

所以对于所有的  $t \in (0, 1, \dots, N_t - 1)$ , 有

$$\lim_{k \rightarrow \infty} |E\{e(t+1, k)\}| \rightarrow 0. \quad \square$$

**注1** 从定理1的证明可以看出, 本算法与 ILC 系统的初始条件无关, 因此, 该算法能允许系统各批次的初始状态不同. 在仿真部分可以看到, 即使 ILC 系统在初始条件下存在漂移, 多次迭代后在  $t \in [1, 2, \dots, N_t]$  上的跟踪误差也能趋于零.

**注2** 当系统输出误差很小(即稳态), 或  $|\Delta u(t, k-1)| = 0$  时,  $\hat{\Phi}(t, k)$  会被重置为  $\hat{\Phi}(t, 1)$ . 因为  $\varepsilon$  为一很小的正数, 由式(8)可知跳变后的  $\hat{\Phi}(t, k)$  对  $u(t, k)$  产生的影响很小, 若  $\varepsilon = 10^{-4}$ , 则其对  $u(t, k)$  的影响不超过  $10^{-4}$ .

**注3** 与文献[12]中的结果相比, 本文在原有系

统基础上引入了数据量化和随机丢包. 如果没有数据量化和数据包丢失, 则定理1中的条件将简化为文献[12]的定理2中的条件.

### 3 仿真实验

本文采用文献[12]中的非仿射非线性系统模型来说明本文所给出的 MFAILC 算法的有效性. 系统模型如下:

$$y(t+1) = \begin{cases} \frac{y(t)}{1+y^2(t)} + u^2(t), & 0 \leq t \leq 300; \\ \frac{y(t)y(t-1)y(t-2)u(t-1) + u(t)}{1+y^2(t-1)+y^2(t-2)}, & 300 < t \leq 600. \end{cases}$$

最大迭代长度  $N_d = 600$ . 因为系统模型信息不可知, 所以本仿真实验只用到系统的输入输出信息. 给定理想输出轨迹如下:

$$y_d(t) = 0.4 \sin(t\pi/50) + 0.3 \cos(t\pi/100).$$

系统初始状态  $y(0, k)$  是区间为  $[-0.02, 0.02]$  的随机数. 在不失一般性的情况下, 第1次迭代时的控制输入信号被设置为零, 即  $u(t, 0) = 0$ ,  $0 \leq t \leq N_d$ . 其他的控制器参数设置为  $\eta = 1$ ,  $\mu = \lambda = 0.5$ ,  $\varepsilon = 10^{-4}$ . 初始重置 PPD 参数选择为 0.8.

为表述随机迭代长度, 令  $N_d - N_1 = 100$ . 因为最大迭代长度  $N_d = 600$ , 所以迭代长度满足  $N_t \in [501, 600]$ .  $\text{Prob}\{N_t = N_1 + l\} = 1/100$ , 其中  $l \in [1, 2, \dots, 100]$ . 各批次迭代长度分布如图2所示.

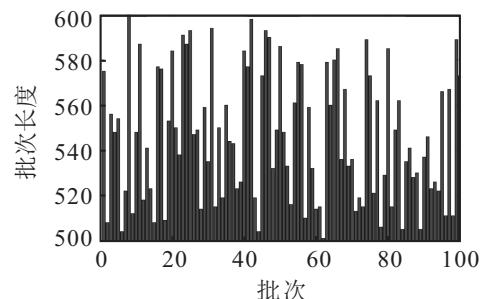


图2 迭代方向上的迭代长度

图3和图4用来说明算法的性能, 其中丢包因子和量化器参数分别选择为  $\alpha = 0.8$  和  $\theta = 0.8$ . 由图3

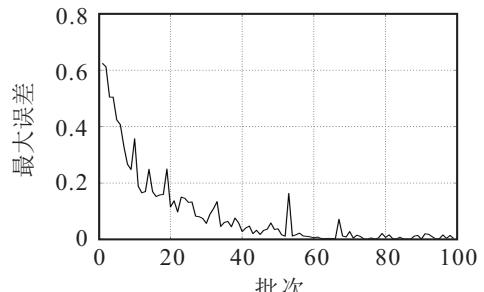
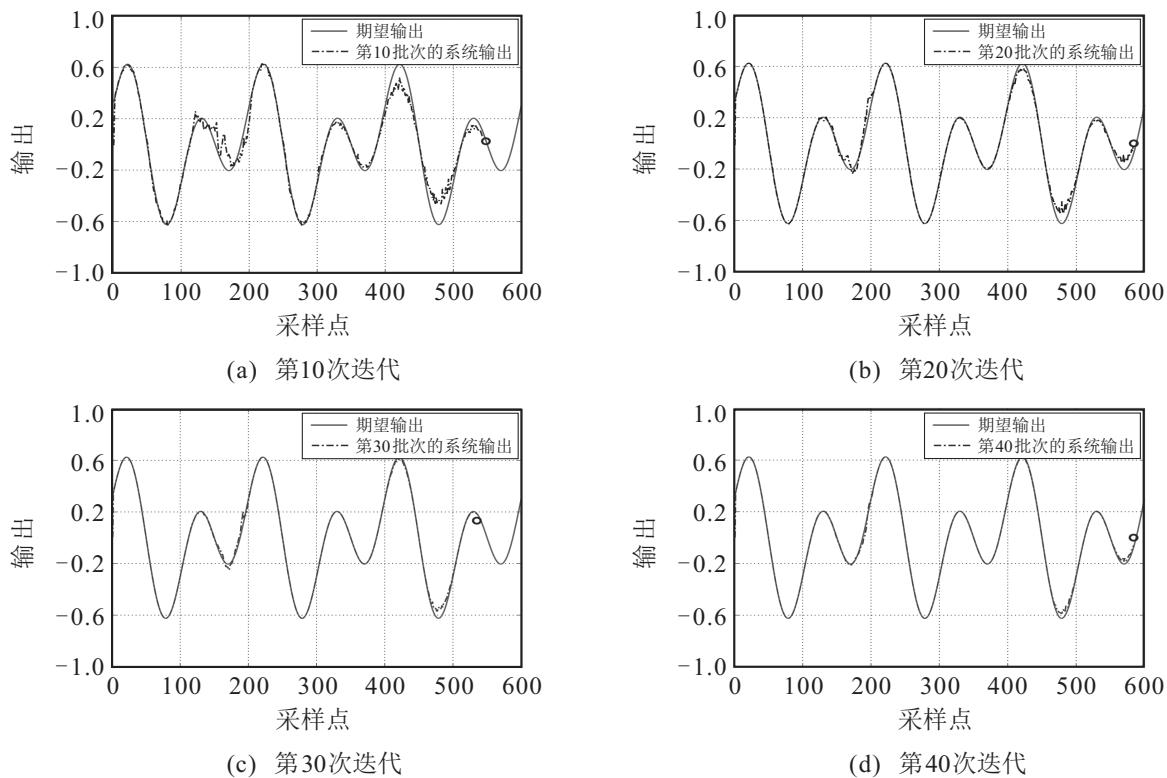


图3 迭代方向上最大轨迹误差

图4  $\alpha = 0.8, \theta = 0.8$ 时系统输出

可以明显看出,即使测量输出经过量化处理并且是随机丢失的,系统也能保证在一定的迭代次数后误差收敛趋于零.

为了更清晰地看到收敛过程,图4给出了第10、20、30、40批次系统的输出轨迹.可以看出:在前几批次系统输出与期望输出有较大的偏差;而在第40批次时系统可以跟踪上理想输出轨迹.

为了对比丢包率对系统性能的影响,选择量化器参数为 $\theta = 0.8$ ,丢包率分别为 $\alpha = 0.8$ 和 $\alpha = 0.5$ ,最大跟踪的对比如图5所示.从图中能够看出,丢包率对收敛速度有直接影响,且丢包率越大收敛速度越慢.

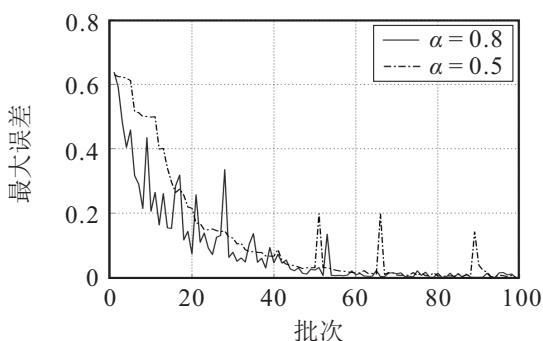
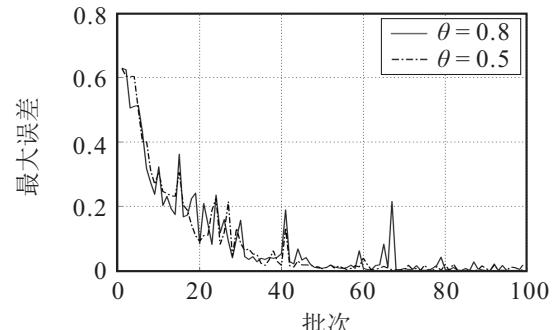
图5  $\alpha = 0.8$ 和 $\alpha = 0.5$ 时系统最大轨迹误差

图6给出了不同量化密度对控制系统影响的对比情况,其中量化密度分别选取 $\theta = 0.8$ 和 $\theta = 0.5$ .结果表明,量化密度的小幅度变化对系统收敛速

度的影响不明显.

图6  $\theta = 0.8$ 和 $\theta = 0.5$ 时系统最大轨迹误差

## 4 结 论

本文针对一类具有随机丢包和测量数据量化的非线性系统,给出了一种无模型自适应迭代学习控制算法.该方法的优点是控制算法设计只需要系统的输出数据来迭代更新学习增益,并且能够适用于各批次迭代长度不同的系统.通过理论分析证明了在有限次迭代后系统跟踪误差的期望趋于零.最后通过仿真实例验证了该方法的有效性.

## 参考文献(References)

- [1] Arimoto S, Kawamura S, Miyazaki F. Bettering operation of robots by learning[J]. Journal of Robotic Systems, 1984, 1(2): 123-140.
- [2] Kim B Y, Lee T, Kim Y S, et al. Iterative learning control for spatially interconnected systems[J]. Applied

- Mathematics and Computation, 2014, 237: 438-445.
- [3] 逢勃, 邵诚. 一种参数优化的非线性离散系统鲁棒迭代学习控制方法[J]. 控制与决策, 2014, 29(3): 449-454.  
(Pang B, Shao C. A robust iterative learning control with parameter-optimization for discrete nonlinear systems[J]. Control and Decision, 2014, 29(3): 449-454.)
- [4] Longman R W, Mombaur K D. Investigating the use of iterative learning control and repetitive control to implement periodic gaits[J]. Lecture Notes in Control and Information Sciences, 2006, 340: 189-218.
- [5] Shen D, Zhang W, Wang Y Q, et al. On almost sure and mean square convergence of P-type ILC under randomly varying iteration lengths[J]. Automatica, 2016, 63(1): 359-365.
- [6] Li X F, Xu J X, Huang D Q. Iterative learning control for nonlinear dynamic systems with randomly varying trial lengths[J]. International Journal of Adaptive Control and Signal Processing, 2015, 29(11): 1341-1353.
- [7] Bu X H, Wang S, Hou Z S, et al. Model free adaptive learning control for a class of nonlinear systems with randomly varying iteration lengths[J]. Journal of the Franklin Institute, 2019, 356(5): 2491-2504.
- [8] Walsh C G, Ye H, Bushnell L G. Stability analysis of networked control systems[J]. IEEE Transactions on Control Systems Technology, 2002, 10(3): 438-446.
- [9] Tang Z, Park J H, Lee T H. Dynamic output-feedback-based  $H_\infty$  design for networked control systems with multipath packet dropouts[J]. Applied Mathematics and Computation, 2016, 275: 121-133.
- [10] Song X M, Duan Z H, Park J H. Linear optimal estimation for discrete-time systems with measurement-delay and packet dropping[J]. Applied Mathematics and Computation, 2016, 284: 115-124.
- [11] Lee T H, Park J H, Jung H. Network-based  $H_\infty$  state estimation for neural networks using imperfect measurement[J]. Applied Mathematics and Computation, 2018, 316: 205-214.
- [12] Bu X H, Hou Z S, Jin S T, et al. An iterative learning control design approach for networked control systems with data dropouts[J]. International Journal of Robust and Nonlinear Control, 2016, 26(1): 91-109.
- [13] Bu X, Hou Z, Yang J. Robust iterative learning control design for linear systems with time-varying delays and packet dropouts[J]. Advances in Difference Equations, 2017, 84: 1-17.
- [14] 卜旭辉, 侯忠生, 余发山, 等. 数据丢失对迭代学习控制的影响分析[J]. 控制与决策, 2014, 29(3): 443-448.  
(Bu X H, Hou Z S, Yu F S, et al. Effect analysis of data dropout on iterative learning contro[J]. Control and Decision, 2014, 29(3): 443-448.)
- [15] Bu X H, Hou Z S, Cui L Z, et al. Stability analysis of quantized iterative learning control systems using lifting representation[J]. International Journal of Adaptive Control and Signal Processing, 2017, 31(9): 1327-1336.
- [16] Xiong W J, Yu X H, Chen Y, et al. Quantized iterative learning consensus tracking of digital networks with limited information communication[J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(6): 1473-1480.
- [17] Hou Z S, Jin S T. A novel data-driven control approach for a class of discrete-time nonlinear systems[J]. IEEE Transactions on Control Systems Technology, 2011, 19(6): 1549-1558.

### 作者简介

刘红霞(1966—), 女, 副教授, 从事先进控制理论与工程应用等研究, E-mail: hongxianjtech@sina.com;

史玄玄(1992—), 男, 硕士生, 从事迭代学习控制、鲁棒控制的研究, E-mail: 981855568@qq.com;

沈谋全(1980—), 男, 教授, 博士, 从事Markov跳变系统、鲁棒控制、有限频控制、事件触发控制等研究, E-mail: shenmouquan@njtech.edu.cn.

(责任编辑: 李君玲)