

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¹, 沈谋全¹, 史玄玄^{1†}

(1. 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

Data driven adaptive learning control of nonlinear network system

Xuanxuan Shi¹, Mouquan Shen¹, Hongxia Liu^{1†}

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

Abstract: This paper considers the problem of data driven iterative learning control (DDILC) for a class of nonaffine nonlinear systems with random iterative lengths, data quantization and random packet dropouts. Resorting to pseudo-partial derivative dynamic technique, such systems fall into time varying linear form. The adaptive learning gain is updated only using the information of former iteration input and incomplete information of system output caused by random iterative lengths, data quantization and random packet dropouts. The prior information of randomly varying iteration lengths and the dynamic information of ILC systems is not required. This design guarantee the the mathematical expectation of tracking errors converge to zero as iteration increases. An illustrative example verifies the effectiveness of the proposed design.

Keywords: data driven design; data quantization; iterative learning control (ILC); 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, 因此受到越来越多的学者和工程师们的关注与研究^[1-3]. 值得注意的是, 在上述结果中系统每批次的迭代长度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^[4]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了越来越多的关注^[4-7]. 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.

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^[8]. 然而, 网络的稳定性及带宽限制也给控制带来新的挑战, 如数据随机丢包问题、数据量化问题、如网络延时问题等^[9-11]. 如果上述问题得

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 (61403189).

[†]通讯作者. E-mail: hongxianjtech@sina.com.

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. 在文献 [15] 中, 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. 尽管这些结果促使了对迭代学习控制的研究, 但应该指出的是, 它们只能用于具有固定迭代长度的迭代学习控制. 虽然 [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, 本文给出了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, 总结出本文的主要贡献如下: (1) 本文仅利用量化后且存在随机丢失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, 而现有针对 ILC 丢包及量化研究的大多文献中都假设迭代批次长度不变. (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. 而在现有 ILC 工程中, 大多假设各批次的初始状态都相同.

1 问题描述

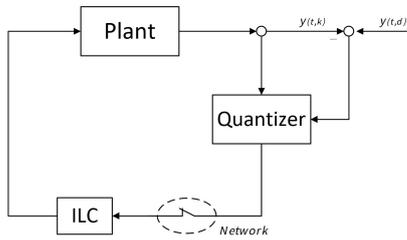


图 1 网络控制系统框图

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, 其中 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. $f(\bullet)$ 是非仿射函数, $q(\bullet)$ 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.

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, 那么系统的实际的批次长度落在区间 $\{N_1, \dots, N_d\}$ 内. 也就是说在时间区间 $[0, N_t]$ 内可以测得系统输出. 为了更清楚的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 $N_t = N_1 + l$, $Prob\{N_t\} = p_l$, 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. 由此可得以下等式:

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

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, 如下所示:

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

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

可以看出量化器 $q(\bullet)$ 是对称的. 应用扇区有界方法得到:

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

其中 $|\Sigma| \leq \delta$.

在不失一般性下做出以下假设:

假设 1 函数 $f(\bullet)$ 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 $\Delta y(t+1, k) = y(t+1, k) - y(t, k)$, $\Delta u(t, k) = u(t, k) - u(t, k-1)$ 且 $b > 0$ 是已知常数.

在上述两个假设的基础上, 引入了以下引理:

引理 1 ^[17] 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:

对于给出理想输出轨迹 $y_d(t), t \in [0, 1, \dots, N_d]$, 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的下的输出轨迹误差的期望 $E\{e(t, k)\} = E\{y_d(t) - y(t, k)\}$ 在有限次的迭代后趋向于 0.

2 主要结果

定义

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

$$\Delta y^*(t, k) = \alpha(t, k)q(y(t, k)) - \alpha(t, k-1)q(y(t, k-1)), \quad (6)$$

PPD 更新项可表示为:

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

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 $\mu > 0$ 表示比重参数, η 为步长参数, $\varepsilon > 0$ 为很小的常数. $\hat{\Phi}(k, 1)$ 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 1-3, 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 $|\Delta u(t, k-1)| \leq \varepsilon$ 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.

除此之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 $\zeta(t, k) = \alpha(t, k) - 1$, $\Theta(t, k) = (1 + \Sigma)(\zeta(t, k) -$

$\zeta(t, k-1))y(t, k-1)$.

结合 $\Delta y^*(t, k)$ 与式 (7) 得到

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

将 (9) 带入到 (8) 得

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

其中 $\Theta_2(t, k) = \gamma(t+1, k-1)\eta\Delta u(t, k-1)\Theta(t+1, k-1)/(\mu + |\Delta u(t, k-1)|^2)$. 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) 对式 (13) 两边取期望得

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

\vdots

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

因此, $E\{\hat{\Phi}(t, k)\}$ 对于所有的 $t \in \{0, 1, 2, \dots, N_t\}$ 有界.

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

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

则系统误差可表示为:

$$e(t+1, k) = (1 - (1 + \Sigma)\gamma(t+1, k-1) \alpha(t+1, k-1) \frac{\rho \hat{\Phi}(t, k) \Phi(t, k)}{\lambda + |\hat{\Phi}(t, k)|^2}) e(t+1, k-1) \quad (15)$$

因为 $E\{\Phi(t, k)\}$ 和 $E\{\hat{\Phi}(t, k)\}$ 都是有界的, 且 $\lambda + |E\{\hat{\Phi}(t, k)\}| \geq 2\sqrt{\lambda}|\hat{\Phi}(t, k)|$, 所以存在 ρ 和 $\lambda > \lambda_{min} > 0$ 满足以下等式

$$0 < \frac{E\{\rho \Phi(t, k) \hat{\Phi}(t, k)\}}{\lambda + |E\{\hat{\Phi}(t, k)\}|^2} \leq \frac{\rho b \hat{\Phi}(t, k)}{2\sqrt{\lambda}|\hat{\Phi}(t, k)|} < 1, \quad (16)$$

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

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

因此, 式 (15) 可写为

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

所以对所有的 $t \in (0, 1, \dots, N_t - 1)$, 有 $\lim_{k \rightarrow \infty} |E\{e(t+1, k)\}| \rightarrow 0$.

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 ε 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] 中的定理 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

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

最大迭代长度 $N_d = 600$. 由于系统模型信息不

可知所以模型本仿真实验只用到系统的输入输出信息. 给出理想输出轨迹如下:

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

系统初始状态 $y(0, k)$ 是区间为 $[-0.02, 0.02]$ 的随机数. 在不失去一般性的情况下, 第一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 $N_t \in [501, 600]$. $Prob\{N_t = N_1 + l\} = 1/100$, 其中 $l \in [1, \dots, 100]$. 各批次迭代长度分布在图 2.

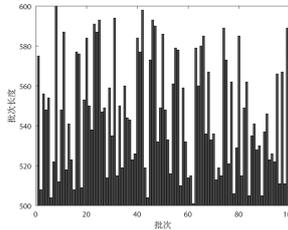


图 2 迭代方向上的迭代长度

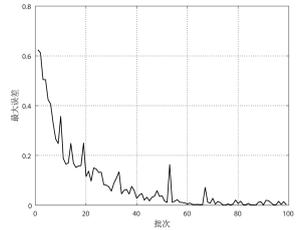
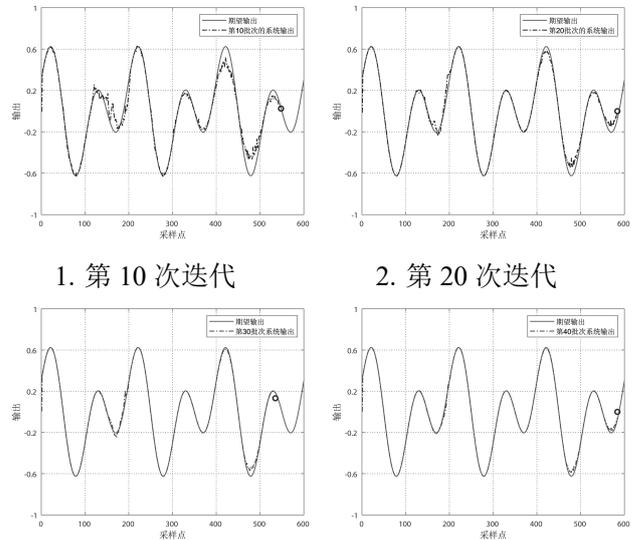


图 3 迭代方向上最大轨迹误差

图 3 和图 4 来说明算法的性能, 其中包丢失因子和量化器参数分别选择为 $\alpha = 0.8$ 和 $\theta = 0.8$ 。由图 3 很明显看出, 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 0。

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. 从表中可以看出, 在前几批次系统输出与期望输出有较大的偏差. 然而, 在第 40 批次时系统可以跟踪上理想输出轨迹.



1. 第 10 次迭代

2. 第 20 次迭代

3. 第 30 次迭代

4. 第 40 次迭代

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

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 6 给出了不同量化密度对控制系统影响的对比图,其中量化密度分别选取 $\theta = 0.8$, $\theta = 0.5$ 。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。

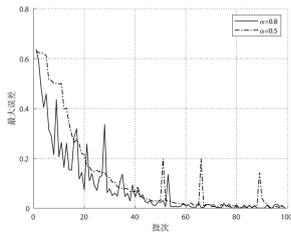


图 5 $\alpha = 0.8$ & $\alpha = 0.5$ 时系统最大
轨迹误差

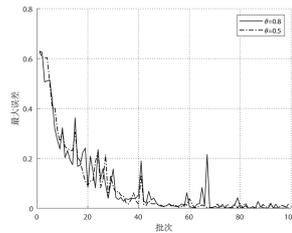


图 6 $\theta = 0.8$ & $\theta = 0.5$ 时系统最大
轨迹误差

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。最后给出仿真实例验证了该方法的有效性。

5 参考文献

参考文献 (References)

[1] Arimoto.S, Kawamura.S, Miyazaki.F. Bettering operation of robots by learning[J], J. Robot. Syst,1984,1(2):12140.

[2] Kim.B, Lee.T, Kim.Y, Ahn.H.Iterative learning control for spatially interconnected systems[J], Appl. Math. Comput. 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 method for nonlinear discrete systems with parametric optimization[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 Control Inform. Sci. 2006,340:189-218.

[5] Shen.D, Zhang.W, Wang.Y, Chien.C.J. 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, Xu.J.X, Huang.D. Iterative learning control for nonlinear dynamic systems with randomly varying trial lengths[J]. Int. J. Adapt. Control Signal Process. 2015,29(11):1341-1353.

[7] Bu.X.H, Sen. W, Hou.Z.H, Liu.W. 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.G, Ye.H, Bushnell.L. Stability analysis of networked control systems[J]. IEEE Trans. Control Syst. Technol. 2002,10(3): 438-446.

[9] Tang.Z, Park.J.H, Lee.T.H. Dynamic output-feedback-based H_{∞} design for networked control systems with multipath packet dropouts[J]. Appl. Math. Comput. 2016, 275:121-133.

[10] Song.X, Duan.Z, Park.J.H. Linear optimal estimation for discrete-time systems with measurement-delay and packet dropping[J]. Appl. Math. Comput. 2016,284:115-124.

[11] Lee.T.H, Park.J.H, Jung.H. Network-based H_{∞} state estimation for neural networks using imperfect measurement[J]. Appl. Math. Comput. 2018,316:205-214.

[12] Bu.X, Hou.Z, Jin.S, Chi.R. An iterative learning control design approach for networked control systems with data dropouts[J]. Int. J. Robust 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]. Adv. Differ. Equ. 2017,2017(1):84.

[14] 卜旭辉, 侯忠生, 余发山. 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. Analysis of the impact of data loss on iterative learning control[J]. Control and Decision, 2014, 29(3):443-448.)

[15] Bu.X, Hou.Z, Cui.L, Yang.J. Stability analysis of quantized iterative learning control systems using lifting representation[J]. Int. J. Adapt. Control Signal Process. 2017,31(9):1327-1336.

[16] Xiong.W, Yu.X, Chen.Y, Gao.J. Quantized iterative learning consensus tracking of digital networks with limited information communication[J]. IEEE Trans. Neural Netw. Learn. Syst. 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 Trans. Control Syst. Technol. 2011,19(6):1549-1558.

作者简介

史玄玄 (1992—), 男, 硕士研究生, 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, 从事 Markov 跳变系统、鲁棒控制、有限频控制、事件触发控制等方向的研究, E-mail: shenmouquan@njtech.edu.cn.

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