

基于ESO迭代学习算法的故障估计

齐晓慧^a, 王俭臣^a, 单甘霖^b

(军械工程学院 a. 无人机工程系, b. 电子与光学工程系, 石家庄 050003)

摘要: 针对基于迭代学习的故障估计器方法, 提出一种基于扩张状态观测器(ESO)思想的迭代学习算法, 以提高虚拟故障的收敛速度. 该算法将ESO的输出误差非线性反馈机制用于迭代学习过程, 利用故障估计器当前输出残差的非线性函数修正下次迭代时的虚拟故障值. 对所建立的故障估计器的收敛性进行理论分析, 并在此基础上进行了仿真实验. 仿真结果表明, 所提出的算法具有良好的收敛速度和故障估计精度.

关键词: 迭代学习; 故障估计; 扩张状态观测器; 虚拟故障

中图分类号: TP273

文献标志码: A

Fault estimation method based on ESO iteration learning algorithm

QI Xiao-hui^a, WANG Jian-chen^a, SHAN Gan-lin^b

(a. Department of Unmanned Plane, b. Department of Electronics and Optics Engineering, Ordnance Engineering College, Shijiazhuang 050003, China. Correspondent: WANG Jian-chen, E-mail: lichen197@163.com)

Abstract: For the fault estimator based on the iterative learning theory, an iterative learning algorithm based on the extended states observer(ESO) is proposed to improve the convergence speed of the virtual fault. In this algorithm, the nonlinear feedback mechanism of the ESO is transplanted to iterative learning processes, that is, the nonlinear function of the current output residual is used to adjust the value of the virtual fault in the next iteration. The theoretical convergence analysis of the proposed fault estimator is proven, based on which some simulation experiments are conducted. The obtained results show the favorable convergence speed and the fault estimation precision of the proposed method.

Keywords: iterative learning; fault estimation; extended state observer(ESO); virtual fault

0 引言

随着现代工程系统对安全性和可靠性的迫切需要, 故障检测与估计以及故障容错等技术越来越受重视^[1-3], 其中故障估计的目的是实现对故障类型及大小的辨识, 这对后续故障容错具有指导意义.

近几年来, 各种基于模型的故障估计技术被不断提出, 主要包括自适应观测器^[4-6]、滑模观测器^[7-8]、迭代观测器^[9-10]等. 文献[11]提出一种方法, 通过在观测器中引入一个虚拟故障参数来构建故障跟踪估计器, 然后通过反复迭代调整虚拟故障参数值, 最终实现故障的完全跟踪估计. 相比其他故障估计方法, 迭代学习方法以可接受的计算代价获得更高的故障估计精度^[12], 已成为故障诊断领域新的研究方向^[13-15]. 文献[11-12]将D型迭代学习律分别用于Lipschitz非线性系统和线性系统的故障估计; 针对离

散型系统, 文献[13]讨论了P型学习律下的故障估计收敛性. 在保证收敛性的基础上, 改善收敛速度是另一重要研究内容. 文献[14]将PID学习律引入故障估计, 即采用故障估计器输出误差的PID信号调节故障估计值; 而针对实际中微分信号不可得的限制, 文献[15]提出了一种比例差分型故障估计策略. 两者的区别是, 文献[14]利用了输出误差在时间轴(t 轴)上的信息, 而文献[15]利用的则是输出误差在迭代轴(k 轴)上的信息.

为提高虚拟故障的收敛速度, 考虑自抗扰控制技术中的扩张状态观测器(ESO)方法^[16], 它利用适当的输出误差非线性反馈实现系统状态和未知扰动的快速跟踪估计, 具有比一般状态观测器(采用误差线性反馈)更好的动态响应品质. 受此启发, 本文将ESO中的非线性反馈设计从时间轴推广到迭代轴, 提出一种

收稿日期: 2014-01-05; 修回日期: 2014-06-09.

基金项目: 国防预研基金项目(513270203); 武器装备预研重点基金项目(9140A27020211JB3402).

作者简介: 齐晓慧(1962-), 女, 教授, 博士生导师, 从事最优化理论、智能控制等研究; 王俭臣(1987-), 男, 博士生, 从事故障诊断、系统辨识的研究.

基于ESO思想的迭代学习故障跟踪估计器. 给出了该故障估计器的收敛性分析, 并通过仿真对比实验说明了其具有良好的故障估计速度. 另外, 由于所提出的故障估计器仅使用当前迭代的输出误差信息, 并未使用输出误差的微分信号, 该算法运算简单, 工程上易于实现.

1 扩张状态观测器简介

考虑如下的系统:

$$\begin{cases} \dot{\mathbf{x}}_1 = \mathbf{w}(\mathbf{x}_1, t) + \mathbf{A}\mathbf{x}_1 + \mathbf{B}\mathbf{u}(t), \\ \mathbf{y} = \mathbf{x}_1. \end{cases} \quad (1)$$

其中: \mathbf{x}_1 为系统状态; $\mathbf{u}(t)$ 为系统输入; $\mathbf{w}(\mathbf{x}_1, t)$ 为系统未知部分, 如建模不确定性或外扰. 根据ESO方法, 将系统未知部分扩展为新的状态 $\mathbf{x}_2 = \mathbf{w}(\mathbf{x}_1, t)$, 然后可设计如下的扩张状态观测器:

$$\begin{cases} \mathbf{e} = \mathbf{z}_1 - \mathbf{y}, \\ \dot{\mathbf{z}}_1 = \mathbf{z}_2 + \mathbf{A}\mathbf{z}_1 + \mathbf{B}\mathbf{u}(t) - \beta_{01}\mathbf{g}_1(\mathbf{e}), \\ \dot{\mathbf{z}}_2 = -\beta_{02}\mathbf{g}_2(\mathbf{e}). \end{cases} \quad (2)$$

其中: \mathbf{z}_1 、 \mathbf{z}_2 分别为观测器状态, β_{01} 、 β_{02} 为适当参数, $\mathbf{g}_i(\mathbf{e})$ ($i = 1, 2$) 为满足条件 $\mathbf{e}\mathbf{g}_i(\mathbf{e}) > 0$ 的适当非线性函数. 在此基础上, 只要选择合适的参数和非线性函数, 上述ESO的状态 \mathbf{z}_1 、 \mathbf{z}_2 就能分别在线估计系统的状态 \mathbf{x}_1 和未知部分 $\mathbf{w}(\mathbf{x}_1, t)$. 一般地, β_{01} 、 β_{02} 可按照 2ω 、 ω^2 的规律取值, ω 为可调参数, $\mathbf{g}_i(\mathbf{e})$ 可取 $\mathbf{g}_1(\mathbf{e}) = \mathbf{e}$ 、 $\mathbf{g}_2(\mathbf{e}) = \text{fal}(\mathbf{e}, 1/2, \delta)$. 其中

$$\text{fal}(\mathbf{e}, \alpha, \delta) = \begin{cases} \frac{\mathbf{e}}{\delta^{\alpha-1}}, & |\mathbf{e}| \leq \delta; \\ |\mathbf{e}|^\alpha \text{sign}(\mathbf{e}), & |\mathbf{e}| > \delta. \end{cases}$$

$\text{sign}(\mathbf{e})$ 为符号函数. 为便于计算机处理, 可将式(2)近似离散化为

$$\begin{cases} \mathbf{e}(t_k) = \mathbf{z}_1(t_k) - \mathbf{y}(t_k), \\ \mathbf{z}_1(t_{k+1}) = \\ \mathbf{z}_1(t_k) + h(\mathbf{z}_2(t_k) + \mathbf{A}\mathbf{z}_1(t_k) + \\ \mathbf{B}\mathbf{u}(t_k) - \beta_{01}\mathbf{g}_1(\mathbf{e}(t_k))), \\ \mathbf{z}_2(t_{k+1}) = \mathbf{z}_2(t_k) + h(-\beta_{02}\mathbf{g}_2(\mathbf{e}(t_k))). \end{cases} \quad (3)$$

其中: t_k 、 t_{k+1} 表示离散化时刻, h 为离散步长.

与一般状态观测器相比, ESO的主要特点是引入观测器输出误差的非线性反馈, 从而使算法对系统状态和未知扰动具有很强的动态跟踪性能.

2 基于迭代学习的故障估计

为便于分析研究, 首先对基于迭代学习的故障跟踪估计器原理介绍如下. 考虑如下包含故障的线性时不变系统:

$$\begin{cases} \dot{\mathbf{x}}(t) = \mathbf{A}\mathbf{x}(t) + \mathbf{B}\mathbf{u}(t) + \mathbf{B}_f\mathbf{f}(t), \\ \mathbf{y}(t) = \mathbf{C}\mathbf{x}(t) + \mathbf{D}\mathbf{u}(t) + \mathbf{D}_f\mathbf{f}(t). \end{cases} \quad (4)$$

其中: \mathbf{A} 、 \mathbf{B} 、 \mathbf{C} 、 \mathbf{D} 为适当维数的系统矩阵, \mathbf{B}_f 、 \mathbf{D}_f 为故障分布矩阵, $\mathbf{f}(t)$ 表示故障. 若上述系统满足以

下假设条件, 则可构建一个故障跟踪估计器:

假设 1 (\mathbf{A} , \mathbf{C}) 满足可观测条件;

假设 2 矩阵 \mathbf{A} 是稳定的;

假设 3 由 $(\mathbf{x}(0), \mathbf{f}(t))$ 到 $\mathbf{x}(t)$ 的状态映射 \mathbf{S} 与由 $\mathbf{x}(0), \mathbf{f}(t)$ 到 $\mathbf{y}(t)$ 的输出映射 \mathbf{O} 是一对一映射^[13].

以如下采用开环P型迭代学习算法的故障跟踪估计器为例:

$$\begin{cases} \dot{\hat{\mathbf{x}}}_k(t) = \mathbf{A}\hat{\mathbf{x}}_k(t) + \mathbf{B}\mathbf{u}(t) + \mathbf{B}_f\hat{\mathbf{f}}_k(t) + \mathbf{L}\mathbf{r}_k(t), \\ \hat{\mathbf{y}}_k(t) = \mathbf{C}\hat{\mathbf{x}}_k(t) + \mathbf{D}\mathbf{u}(t) + \mathbf{D}_f\hat{\mathbf{f}}_k(t), \\ \mathbf{r}_k(t) = \mathbf{y}(t) - \hat{\mathbf{y}}_k(t), \\ \hat{\mathbf{f}}_{k+1}(t) = \hat{\mathbf{f}}_k(t) + \mathbf{\Gamma}\mathbf{r}_k(t). \end{cases} \quad (5)$$

其中: $\hat{\mathbf{x}}_k(t)$ 、 $\hat{\mathbf{y}}_k(t)$ 分别为对系统(4)中状态和输出的观测值; $\hat{\mathbf{f}}_k(t)$ 为引入的虚拟故障, 它通过上述故障跟踪估计器在计算机虚拟时空中重复运行, 采用迭代学习算法不断进行修正; 下标 k 表示在当前优化时域 $t \in [t_n - P, t_n]$ 内的迭代学习次数, P 为设定的优化时域长度; $\mathbf{\Gamma}$ 为迭代学习增益矩阵; \mathbf{L} 为观测器增益矩阵, 满足矩阵 $\mathbf{A} - \mathbf{L}\mathbf{C}$ 稳定; $\mathbf{r}_k(t)$ 为第 k 次迭代学习后故障估计器的输出 $\hat{\mathbf{y}}_k(t)$ 与系统实际输出 $\mathbf{y}(t)$ 的差.

另外, 设置一个残差阈值 ε , 若

$$\|\mathbf{y}(t) - \hat{\mathbf{y}}_k(t)\|_\infty > \varepsilon,$$

则故障跟踪估计器启动迭代学习过程. 算法启动后, 一旦满足

$$\|\mathbf{y}(t) - \hat{\mathbf{y}}_k(t)\|_\infty \leq \varepsilon,$$

则当前优化时域内的迭代学习停止, 以避免过多的迭代次数. 在此基础上, 采用模型预测控制中的滚动优化思想, 只要在下一个优化时域到来前完成当前优化时域内的虚拟故障迭代学习过程, 就可以在线不断地估计出系统中所发生的故障.

2.1 新算法描述

为便于研究, 首先引入以下定义和引理.

定义 1 向量函数 $\mathbf{f} : [0, T] \rightarrow \mathbb{R}^n$ 的 λ 范数为

$$\|\mathbf{f}\|_\lambda = \sup_{0 \leq t \leq T} \{\|\mathbf{f}(t)\| e^{-\lambda t}\}, \lambda > 0.$$

引理 1^[17] 设 $\mathbf{x}(t)$ 、 $\mathbf{y}(t)$ 为 $[0, T]$ 上的实值连续函数, 若

$$\mathbf{x}(t) \leq c + \int_0^t (a\mathbf{x}(\tau) + b\mathbf{y}(\tau))d\tau, a \geq 0,$$

则

$$\mathbf{x}(t) \leq ce^{at} + \int_0^t e^{a(t-\tau)}b\mathbf{y}(\tau)d\tau.$$

对于式(4)所示线性系统, 将ESO输出误差在时间轴(t 轴)上的处理方法推广到故障估计器的迭代轴(k 轴), 则可得到如下新的故障估计器:

$$\begin{cases} \dot{\hat{\boldsymbol{x}}}_k(t) = \boldsymbol{A}\hat{\boldsymbol{x}}_k(t) + \boldsymbol{B}\boldsymbol{u}(t) + \boldsymbol{B}_f\hat{\boldsymbol{f}}_k(t) + \\ \quad \beta_{01}\boldsymbol{g}_1(\boldsymbol{r}_k(t)), \\ \hat{\boldsymbol{y}}_k(t) = \boldsymbol{C}\hat{\boldsymbol{x}}_k(t) + \boldsymbol{D}\boldsymbol{u}(t) + \boldsymbol{D}_f\hat{\boldsymbol{f}}_k(t), \\ \boldsymbol{r}_k(t) = \boldsymbol{y}(t) - \hat{\boldsymbol{y}}_k(t), \\ \hat{\boldsymbol{f}}_{k+1}(t) = \hat{\boldsymbol{f}}_k(t) + \beta_{02}\boldsymbol{g}_2(\boldsymbol{r}_k(t)). \end{cases} \quad (6)$$

其中: 参数 β_{01} 、 β_{02} 可按照 2ω 、 ω^2 的规律取值; 可调参数 ω 的取值要保证矩阵 $(\boldsymbol{A} - 2\omega\boldsymbol{I}_{n \times m}\boldsymbol{C})$ 稳定, 其中 $\boldsymbol{I}_{n \times m} = [\boldsymbol{I}_{m \times m}, \mathbf{0}_{(n-m) \times m}]^T$.

实际上, 式 (6) 所示的基于 ESO 思想的迭代学习故障估计器与系统的 ESO 具有相似结构, 区别是输出误差的非线性反馈是在迭代轴上进行的.

2.2 收敛性分析

定理 1 对式 (4) 所示的系统设计如式 (6) 所示的故障估计器. 不失一般性, 若在选定的优化时域 $t \in [0, t_p]$ 上, 满足如下两个条件:

1) 系统状态和输出初始值已知, 即

$$\hat{\boldsymbol{x}}_k(0) = \boldsymbol{x}(0), \hat{\boldsymbol{y}}_k(0) = \boldsymbol{y}(0), k = 1, 2, \dots;$$

2) 非线性函数 $\boldsymbol{g}_2(\boldsymbol{r}_k(t)) = \text{fal}(\boldsymbol{r}_k(t), 1/2, \delta)$ 使得

$$\|\boldsymbol{I} - \boldsymbol{\eta}\boldsymbol{D}_f\| < 1,$$

其中

$$\boldsymbol{\eta} = \beta_{02} \text{diag} \left(\frac{\boldsymbol{g}_2(\boldsymbol{r}_{k1}(t))}{\boldsymbol{r}_{k1}(t)}, \frac{\boldsymbol{g}_2(\boldsymbol{r}_{k2}(t))}{\boldsymbol{r}_{k2}(t)}, \dots, \frac{\boldsymbol{g}_2(\boldsymbol{r}_{kn}(t))}{\boldsymbol{r}_{kn}(t)} \right)$$

为对角矩阵. 则可得到如下结论:

1) 故障估计器的输出可以无限逼近系统实际的输出, 即

$$\lim_{k \rightarrow \infty} \|\boldsymbol{y}(t) - \hat{\boldsymbol{y}}_k(t)\|_\lambda = 0, t \in [0, t_p];$$

2) 虚拟故障 $\hat{\boldsymbol{f}}(t)$ 在 $[0, t_p]$ 上无限逼近实际故障,

即

$$\begin{aligned} \lim_{k \rightarrow \infty} \|\tilde{\boldsymbol{f}}_k(t)\|_\lambda &= \\ \lim_{k \rightarrow \infty} \|\boldsymbol{f}(t) - \hat{\boldsymbol{f}}_k(t)\|_\lambda &= 0, t \in [0, t_p]. \end{aligned}$$

证明 定义 $\tilde{\boldsymbol{f}}_k(t) = \boldsymbol{f}(t) - \hat{\boldsymbol{f}}_k(t)$. 在优化时域 $[0, t_p]$ 上, 由每次迭代学习的初始值相同可得

$$\begin{aligned} \boldsymbol{x}(t) - \hat{\boldsymbol{x}}_k(t) &= \\ (\boldsymbol{x}(0) - \hat{\boldsymbol{x}}_k(0)) + \int_0^t [\boldsymbol{A}\boldsymbol{x}(\tau) + \boldsymbol{B}\boldsymbol{u}(\tau) + \boldsymbol{B}_f\boldsymbol{f}(\tau)] d\tau - \\ \int_0^t [\boldsymbol{A}\hat{\boldsymbol{x}}_k(\tau) + \boldsymbol{B}\boldsymbol{u}(\tau) + \boldsymbol{B}_f\hat{\boldsymbol{f}}_k(\tau)] d\tau - \\ \int_0^t 2\omega\boldsymbol{I}_{n \times m}(\boldsymbol{y}(\tau) - \hat{\boldsymbol{y}}_k(\tau)) d\tau &= \\ \int_0^t (\boldsymbol{A} - 2\omega\boldsymbol{I}_{n \times m}\boldsymbol{C})(\boldsymbol{x}(\tau) - \hat{\boldsymbol{x}}_k(\tau)) d\tau + \\ \int_0^t (\boldsymbol{B}_f - 2\omega\boldsymbol{I}_{n \times m}\boldsymbol{D}_f)(\boldsymbol{f}(\tau) - \hat{\boldsymbol{f}}_k(\tau)) d\tau. \end{aligned}$$

对上式取范数, 并由引理 1 可得

$$\begin{aligned} \|\boldsymbol{x}(t) - \hat{\boldsymbol{x}}_k(t)\| &\leq \\ b_2 \int_0^t e^{b_1(t-\tau)} \|\boldsymbol{f}(\tau) - \hat{\boldsymbol{f}}_k(\tau)\| d\tau &\leq \\ b_2 b_3 \int_0^t \|\tilde{\boldsymbol{f}}_k(\tau)\| d\tau. \end{aligned} \quad (7)$$

其中

$$\begin{aligned} b_1 &= \|\boldsymbol{A} - 2\omega\boldsymbol{I}_{n \times m}\boldsymbol{C}\|, \\ b_2 &= \|\boldsymbol{B}_f - 2\omega\boldsymbol{I}_{n \times m}\boldsymbol{D}_f\|, \\ b_3 &= e^{b_1 t_n}. \end{aligned}$$

由故障逼近误差定义可知

$$\begin{aligned} \tilde{\boldsymbol{f}}_{k+1}(t) &= \boldsymbol{f}(t) - \hat{\boldsymbol{f}}_{k+1}(t) = \\ \boldsymbol{f}(t) - \hat{\boldsymbol{f}}_k(t) - \beta_{02}\boldsymbol{g}_2(\boldsymbol{r}_k(t)) &= \\ \tilde{\boldsymbol{f}}_k(t) - \beta_{02}\boldsymbol{g}_2(\boldsymbol{y}(t) - \boldsymbol{y}_k(t)) &= \\ \tilde{\boldsymbol{f}}_k(t) - \boldsymbol{\eta}(\boldsymbol{C}(\boldsymbol{x}(t) - \boldsymbol{x}_k(t)) + \boldsymbol{D}_f\tilde{\boldsymbol{f}}_k(t)). \end{aligned} \quad (8)$$

其中

$$\boldsymbol{\eta} = \beta_{02} \text{diag} \left(\frac{\boldsymbol{g}_2(\boldsymbol{r}_{k1}(t))}{\boldsymbol{r}_{k1}(t)}, \frac{\boldsymbol{g}_2(\boldsymbol{r}_{k2}(t))}{\boldsymbol{r}_{k2}(t)}, \dots, \frac{\boldsymbol{g}_2(\boldsymbol{r}_{kn}(t))}{\boldsymbol{r}_{kn}(t)} \right)$$

为对角矩阵, n 为系统状态的维数.

对式 (8) 取范数, 得

$$\begin{aligned} \|\tilde{\boldsymbol{f}}_{k+1}(t)\| &\leq \\ \|\boldsymbol{I} - \boldsymbol{\eta}\boldsymbol{D}_f\| \|\tilde{\boldsymbol{f}}_k(t)\| + b_4 \|\boldsymbol{x}(t) - \boldsymbol{x}_k(t)\|, \end{aligned} \quad (9)$$

其中 $b_4 = \|\boldsymbol{\eta}\boldsymbol{C}\|$.

将式 (7) 代入 (9), 得

$$\begin{aligned} \|\tilde{\boldsymbol{f}}_{k+1}(t)\| &\leq \\ \|\boldsymbol{I} - \boldsymbol{\eta}\boldsymbol{D}_f\| \|\tilde{\boldsymbol{f}}_k(t)\| + b_4 b_2 b_3 \int_0^t \|\tilde{\boldsymbol{f}}_k(\tau)\| d\tau. \end{aligned} \quad (10)$$

式 (10) 两边同乘 $e^{-\lambda t}$, 并由定义 1 可得

$$\begin{aligned} \|\tilde{\boldsymbol{f}}_{k+1}(t)\|_\lambda &\leq \\ \|\boldsymbol{I} - \boldsymbol{\eta}\boldsymbol{D}_f\| \|\tilde{\boldsymbol{f}}_k(t)\|_\lambda + b_4 b_2 b_3 \frac{1 - e^{-\lambda t_n}}{\lambda} \|\tilde{\boldsymbol{f}}_k(t)\|_\lambda. \end{aligned}$$

因此, 取 λ 足够大时, 由定理 1 的假设条件 $\|\boldsymbol{I} - \boldsymbol{\eta}\boldsymbol{D}_f\| < 1$ 可知, 在优化时域 $[0, t_p]$ 上, 有

$$\lim_{k \rightarrow \infty} \|\tilde{\boldsymbol{f}}_k(t)\|_\lambda = \lim_{k \rightarrow \infty} \|\boldsymbol{f}(t) - \hat{\boldsymbol{f}}_k(t)\|_\lambda = 0, \quad (11)$$

即结论 2) 成立.

由式 (7) 可知, 在优化时域 $[0, t_p]$ 上, $\lim_{k \rightarrow \infty} \|\boldsymbol{x}(t) - \hat{\boldsymbol{x}}_k(t)\| = 0$. 进一步, 有

$$\begin{aligned} \lim_{k \rightarrow \infty} \|\boldsymbol{y}(t) - \hat{\boldsymbol{y}}_k(t)\| &\leq \\ \|\boldsymbol{C}\| \lim_{k \rightarrow \infty} \|\boldsymbol{x}(t) - \hat{\boldsymbol{x}}_k(t)\| + \\ \|\boldsymbol{D}\| \lim_{k \rightarrow \infty} \|\boldsymbol{f}(t) - \hat{\boldsymbol{f}}_k(t)\| &= 0, \end{aligned}$$

结论 1) 得证. \square

3 仿真实验

将本文所提出的基于 ESO 思想的迭代学习故障

估计算法(简称ESO型算法)用于如下含有故障的线性时不变系统^[15]:

$$\dot{\mathbf{x}}(t) = \begin{bmatrix} -2 & 3 \\ 0 & -1 \end{bmatrix} \mathbf{x}(t) + \begin{bmatrix} 1 \\ 0 \end{bmatrix} u(t) + \begin{bmatrix} f(t) \\ 0 \end{bmatrix},$$

$$y(t) = [2 \ 0] \mathbf{x}(t) + u(t) + f(t).$$

实验1 按照式(6)建立故障跟踪估计器,取非线性反馈函数 $g_2(e) = \text{fal}(e, 1/2, 0.01)$, 可调参数 $\omega = 8$. 另外, 将P型和比例差分型^[15]迭代学习故障估计器用于仿真对比实验, 设置P型算法的迭代学习增益分别为 $L_p = 3$ 和 $L_p = 6$, 设置比例差分型算法的迭代学习增益为 $L_p = 6, L_d = 2$. 三种算法具有如下相同的迭代学习参数设置: 优化时域长度 $P = 0.1 \text{ s}$, 迭代学习残差阈值 $\varepsilon = 0.0001$. 假设故障函数为如下的指数函数:

$$f(t) = \begin{cases} e^{0.05t}, & 5 \text{ s} \leq t \leq 10 \text{ s}; \\ 0, & \text{其他}. \end{cases}$$

仿真结果如图1~图3所示, 其中图1和图3中的P型算法采用迭代学习增益 $L_p = 3$. 由图1可知, 当设置残差阈值足够小时, 3种基于迭代学习的故障跟踪估计算法均可精确地估计出实际故障. 但图2显示, 3种算法的收敛速度不尽相同: $L_p = 3$ 时P型算法收敛最慢, 增大 $L_p = 6$ 时, 算法收敛速度加快, 但算法初始阶段出现了收敛过程振荡; 相比之下, 比例差分型算法初期收敛速度很快而且避免了收敛振荡, 体现了引入迭代误差差分信号的优越性; 而ESO型算法整体的收敛速度最快, 特别是在算法后期, 具有更高的收敛精度. 图3则绘出了故障发生时间内(即5~10s), 3种算法在每个优化时域上所需的迭代学习次数. 可以看到, 在每个优化时域上, ESO型算法所需的迭代学习次数最少. 由图3结果还可以发现, 在5s和10s两个时刻所在的优化时域上, 3种算法的迭代学习次数均明显大于其他优化时域所需迭代学习次数. 这是由于仿真中第*i*个优化时域上的虚拟故障初始值设置为第*i*-1时域右端点时刻的虚拟故障学习结果, 而5s和10s两个时刻对应于系统中故障值发生跳变的时刻, 因此虚拟故障的初始值与实际故障值相差很大, 需要更多的迭代学习次数.




图1 设置 $\varepsilon = 0.0001$ 时的故障估计结果




图2 第1个优化时域内故障残差收敛曲线





图3 达到 $\varepsilon = 0.0001$ 所需迭代次数


实验2 假设有如下的阶跃型故障函数:

$$f(t) = \begin{cases} 5, & 5 \text{ s} \leq t \leq 10 \text{ s}; \\ 0, & \text{其他}. \end{cases}$$

设置每个优化时域上的迭代学习次数相同, 即最大迭代次数 $\text{iter_max} = 40$, 比较3种算法的故障收敛精度. 优化时域长度 P 仍设为 0.1 s , 所采用算法与实验1相同, 其中P型算法仍选用 $L_p = 3$. 三种算法的故障估计结果如图4所示, 结果显示ESO型算法的估计精度高于其他两种算法.



(a) 故障估计结果



(b) 图4(a)局部放大

图4 相同迭代次数时的收敛精度比较

4 结论

受扩张状态观测器(ESO)的输出误差非线性反

馈思想的启发,本文提出一种新的迭代学习算法,并将其用于故障跟踪估计器设计.对所建立的故障估计器的收敛性进行了理论分析,并通过仿真对比实验表明了所提出的算法能够精确地估计出实际故障值,而且具有更快的收敛速度和故障估计精度.此外,由于仅使用了当前迭代过程的输出误差信息,该算法在工程上易于应用.将所提出的方法推广到更为复杂的非线性、时变系统是下一步的研究重点.

参考文献(References)

- [1] Hwang I, Kim S, Kim Y, et al. A survey of fault detection, isolation, and reconfiguration methods[J]. *IEEE Trans on Control Systems Technology*, 2010, 18(3): 636-653.
- [2] Jiang J. Fault-tolerant control systems: An introductory overview[J]. *Acta Automatica Sinica*, 2005, 31(1): 161-174.
- [3] Zhang Y M, Jiang J. Bibliographical review on reconfigurable fault-tolerant control systems[J]. *Annual Reviews in Control*, 2008, 32(2): 229-252.
- [4] Zhang X D, Marios M P, Thomas Parisini. Fault diagnosis of a class of nonlinear uncertain systems with Lipschitz nonlinearities using adaptive estimation[J]. *Automatica*, 2010, 46(2): 290-299.
- [5] Zhang X D. Sensor bias fault detection and isolation in a class of nonlinear uncertain systems using adaptive estimation[J]. *IEEE Trans on Automatic Control*, 2011, 56(5): 1220-1226.
- [6] Jiang B, Staroswiecki M, Cocquempot V. Fault accommodation for nonlinear dynamic systems[J]. *IEEE Trans on Automatic Control*, 2006, 51(9): 1578-1583.
- [7] 何静, 邱静, 张昌凡. 基于微分同胚变换的故障重构算法[J]. *控制理论与应用*, 2010, 27(4): 481-487.
(He J, Qiu J, Zhang C F. Fault reconstruction based on global diffeomorphic coordination transformation[J]. *Control Theory & Application*, 2010, 27(4): 481-487.)
- [8] Tan C P, Edwards C. Robust fault reconstruction in uncertain linear systems using multiple sliding mode observers in cascade[J]. *IEEE Trans on Automatic Control*, 2010, 55(4): 855-880.
- [9] 贾庆贤, 张迎春, 沈毅, 等. 基于迭代学习-未知输入观测器的卫星姿控系统鲁棒故障重构[J]. *系统工程与电子技术*, 2012, 34(1): 120-124.
(Jia Q X, Zhang Y C, Shen Y, et al. Robust fault reconstruction method for satellite attitude control system based on iterative learning-unknown input observer[J]. *System Engineering and Electronics*, 2012, 34(1): 120-124.)
- [10] Wu Q, Mehrdad S. Robust fault diagnosis of a satellite system using a learning strategy and second order sliding mode observer[J]. *IEEE Systems J*, 2010, 4(1): 112-121.
- [11] 颜秉勇, 田作华, 施颂椒, 等. 基于故障跟踪估计器的非线性时滞系统故障诊断[J]. *控制与决策*, 2009, 24(1): 133-136.
(Yan B Y, Tian Z H, Shi S J, et al. Fault diagnosis for nonlinear time-delay systems based on fault tracking approximator[J]. *Control and Decision*, 2009, 24(1): 133-136.)
- [12] 颜秉勇, 王华忠. 基于故障跟踪估计器的故障诊断新方法[J]. *系统工程与电子技术*, 2013, 35(2): 377-380.
(Yan B Y, Wang H Z. Novel fault diagnosis approach based on fault tracking approximator[J]. *Systems Engineering and Electronics*, 2013, 35(2): 377-380.)
- [13] 曹伟, 丛望, 李金, 等. 基于迭代学习的离散线性时变系统故障诊断[J]. *控制与决策*, 2013, 28(1): 137-140.
(Cao W, Cong W, Li J, et al. Fault diagnosis of discrete linear time-varying system based on iterative learning[J]. *Control and Decision*, 2013, 28(1): 137-140.)
- [14] 高林, 刘喜梅, 顾幸生. 一种新的基于迭代学习的故障检测和估计算法[J]. *控制与决策*, 2010, 25(8): 1173-1177.
(Gao L, Liu X M, Gu X S. New fault detection and estimation algorithm based on iterative learning[J]. *Control and Decision*, 2010, 25(8): 1173-1177.)
- [15] 曹伟, 丛望, 孙明. 基于比例差分型迭代学习的故障诊断算法[J]. *系统工程与电子技术*, 2012, 34(10): 2106-2109.
(Cao W, Cong W, Sun M. Fault diagnosis algorithm based on proportional difference type iteration learning[J]. *Systems Engineering and Electronics*, 2012, 34(10): 2106-2109.)
- [16] 韩京清. 自抗扰控制技术——估计补偿不确定因素的控制技术[M]. 北京: 国防工业出版社, 2008: 183-242.
(Han J Q. Active disturbance rejection control technique—The technique for estimating and compensating the uncertainties[M]. Beijing: National Defense Industry Press, 2008: 183-242.)
- [17] 孙明轩, 黄宝健. 迭代学习控制[M]. 北京: 国防工业出版社, 1999: 271-272.
(Sun M X, Huang B J. Iterative learning control[M]. Beijing: National Defense Industry Press, 1999: 271-272.)

(责任编辑: 曹洪武)