

文章编号: 1001-0920(2013)01-0137-04

基于迭代学习的离散线性时变系统故障诊断

曹伟^{1,2}, 丛望¹, 李金¹, 郭媛²

(1. 哈尔滨工程大学 自动化学院, 哈尔滨 150001; 2. 齐齐哈尔大学
计算机与控制工程学院, 黑龙江 齐齐哈尔 161006)

摘要: 针对一类离散线性时变系统的故障诊断问题, 提出一种新的故障检测与估计算法. 该算法通过引入虚拟故障构建离散故障跟踪估计器, 在选取的优化时域内, 利用估计器输出和系统实际输出产生的残差信号, 采用迭代学习算法来调节虚拟故障, 使虚拟故障逼近系统中实际发生的故障, 从而达到对系统故障诊断的目的. 该方法不仅能检测出系统不同类型的故障, 还可以实现对故障信号的精确估计. 仿真结果验证了所提出方法的有效性.

关键词: 离散线性时变系统; 迭代学习; 虚拟故障; 故障诊断

中图分类号: TP273

文献标志码: A

Fault diagnosis of discrete linear time-varying system based on iterative learning

CAO Wei^{1,2}, CONG Wang¹, LI Jin¹, GUO Yuan²

(1. College of Automation, Harbin Engineering University, Harbin 150001, China; 2. College of Computer and Control Engineering, Qiqihar University, Qiqihar 161006, China. Correspondent: CAO Wei, E-mail: yiyuqq@yahoo.cn)

Abstract: Aiming at the fault diagnosis in a class of discrete linear time-varying system, a novel fault detection and estimation algorithm is proposed. This algorithm uses an introduced virtual fault to construct a discrete fault tracking estimator, and then uses the iterative learning algorithm to regulate the virtual fault close to the practical fault based on the difference between outputs of the estimator and the practical system within the chosen optimization time, thereby reaching the end of the fault diagnosis. This algorithm not only can detect the different-type fault of the system, but also can estimate the fault signal accurately. Simulation results show the effectiveness of this algorithm.

Key words: discrete linear time-varying system; iterative learning; virtual fault; fault diagnosis

0 引言

随着人们对复杂系统可靠性和安全性要求越来越高, 故障诊断技术在近几十年中得到了飞速发展, 并取得了大量的研究成果^[1-4]. 随着计算机技术的发展, 计算机控制系统已越来越广泛地应用于工业生产过程中. 计算机控制系统实质上是一种离散时间系统, 作为离散时间系统的研究热点之一, 离散系统的故障诊断技术得到广泛关注. 对于离散线性系统故障诊断技术的研究已取得了丰富的研究成果^[5-8]. 例如: 文献[5]研究了离散周期系统故障检测滤波器设计问题, 文献[6]针对离散线性时变系统设计了鲁棒故障检测滤波器, 文献[7]研究了含有测量时滞的离散线性系统故障诊断问题, 文献[8]研究了一类可用 T-S 模

糊模型描述的离散奇异系统基于等价空间的故障检测问题. 然而上述文献的设计方法计算过程过于复杂, 为工程实践带来不便.

迭代学习控制技术适用于具有重复运动性质的被控系统, 其目标是实现有限区间上的完全跟踪任务. 它通过对被控系统进行控制尝试, 以输出信号与给定目标的偏差修正不理想的控制信号, 使得系统的跟踪性能得以提高. 自 Arimoto 等人^[9]提出该技术以来, 控制领域内发表了大量的研究成果^[10-12], 这是因为迭代学习控制的研究对具有较强的非线性耦合、较高的位置重复精度、难以建模和高精度轨迹跟踪控制要求的动力学系统有着重要的意义. 文献[13-14]将连续迭代学习策略应用到故障诊断中, 实现了连续系统的故

收稿日期: 2011-07-02; 修回日期: 2011-09-15.

基金项目: 国家自然科学基金项目(60672015); 黑龙江省教育厅基金项目(11541390).

作者简介: 曹伟(1977-), 男, 讲师, 博士生, 从事先进控制理论与应用的研究; 丛望(1958-), 男, 教授, 博士生导师, 从事电力系统非线性控制等研究.

障检测与估计. 该方法不需要故障的先验知识, 只需要很少一部分系统运行的历史数据即可估计出系统中发生的故障, 可以实时在线地进行检测和估计系统中的故障, 具有重要的理论价值和实际意义. 然而由于离散时间系统本身的特点(如固有的一步延时, 控制采样间隔的影响等), 基于连续时间域得到的结果一般不能直接照搬到离散时间系统中, 并且从实现角度来看, 基于迭代学习的离散形式的故障跟踪估计器更为直接, 更方便工程应用. 因此, 研究基于迭代学习的离散系统故障诊断算法是必要的.

针对上述问题, 本文将文献[13-14]的思想作进一步的扩展. 将迭代学习策略应用到离散线性时变系统的故障诊断中, 利用含有故障的实际系统输出和设计的离散故障跟踪估计器的输出构造出残差信号. 并利用残差信号通过迭代学习算法对引入的虚拟故障逐次修正, 使虚拟故障逼近系统中实际发生的故障, 从而达到对系统故障诊断的目的.

1 故障诊断方法研究

1.1 新算法的提出

本文针对一类含有故障的离散线性时变系统, 采用迭代学习算法, 提出了一种新的故障检测和估计算法. 为了便于研究, 引入以下定义.

定义 1 离散时间向量函数^[15] $l: [0, T] \rightarrow \mathbf{R}^n$ 的 λ 范数定义为

$$\|l\|_\lambda = \sup_{t \in [0, T]} \{\lambda^t \|l(t)\|\}, \quad 0 < \lambda < 1,$$

其中 $\|\cdot\|$ 为 \mathbf{R}^n 上的一种向量范数.

考虑重复操作下的一类含有故障的离散线性时变系统

$$\mathbf{x}(t+1) = \mathbf{A}(t)\mathbf{x}(t) + \mathbf{B}(t)\mathbf{u}(t) + \mathbf{B}_f(t)\mathbf{f}(t), \quad (1)$$

$$\mathbf{y}(t) = \mathbf{C}(t)\mathbf{x}(t). \quad (2)$$

其中: $t \in \{0, 1, \dots, T\}$, 记为 $0 \leq t \leq T$; $\mathbf{x}(t) \in \mathbf{R}^n$ 为系统状态向量; $\mathbf{u}(t) \in \mathbf{R}^p$ 为系统控制输入向量; $\mathbf{y}(t) \in \mathbf{R}^q$ 为系统输出向量; $\mathbf{f}(t) \in \mathbf{R}^l$ 为需要检测和估计的故障信号; $\mathbf{A}(t)$, $\mathbf{B}(t)$, $\mathbf{B}_f(t)$, $\mathbf{C}(t)$ 为已知的适当维数的矩阵.

假设 1 $(\mathbf{A}(t), \mathbf{C}(t))$ 可观测.

假设 2 矩阵 $\mathbf{A}(t)$ 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} 和由 $(\mathbf{x}(0), \mathbf{f}(t))$ 到 $\mathbf{y}(t)$ 的状态映射 \mathbf{O} 是一一对一的映射.

注 1 映射 \mathbf{S} 和映射 \mathbf{O} 是一一对一的映射, 可保证被估计参数的可辨识性.

首先定义状态误差 $\tilde{\mathbf{x}}_k(t) = \mathbf{x}(t) - \hat{\mathbf{x}}_k(t)$, 输出误差(即残差信号) $\mathbf{h} = \mathbf{y}(t) - \hat{\mathbf{y}}_k(t)$, 故障调节误差 $\tilde{\mathbf{f}}_k(t)$

$= \mathbf{f}(t) - \hat{\mathbf{f}}_k(t)$; 然后建立离散故障跟踪估计器为

$$\hat{\mathbf{x}}_k(t+1) = \mathbf{A}(t)\hat{\mathbf{x}}_k(t) + \mathbf{B}(t)\mathbf{u}(t) + \mathbf{B}_f(t)\hat{\mathbf{f}}_k(t) + \mathbf{L}(\mathbf{y}(t) - \hat{\mathbf{y}}_k(t)), \quad (3)$$

$$\hat{\mathbf{y}}_k(t) = \mathbf{C}(t)\hat{\mathbf{x}}_k(t), \quad (4)$$

$$\tilde{\mathbf{x}}_k(t) = \mathbf{x}(t) - \hat{\mathbf{x}}_k(t), \quad (5)$$

$$\mathbf{h}_k(t) = \mathbf{C}(t)\tilde{\mathbf{x}}_k(t), \quad (6)$$

$$\hat{\mathbf{f}}_{k+1}(t) = \hat{\mathbf{f}}_k(t) + \mathbf{K}(t)\mathbf{h}_k(t+1), \quad (7)$$

$$\|\mathbf{y}(t) - \hat{\mathbf{y}}_k(t)\|_\infty > \varepsilon. \quad (8)$$

其中: $t \in \{0, 1, \dots, T\}$, 记为 $0 \leq t \leq T$; $\hat{\mathbf{x}}_k(t) \in \mathbf{R}^n$ 和 $\hat{\mathbf{y}}_k(t) \in \mathbf{R}^q$ 分别为系统状态和系统输出的估计值, 下标 k 表示在优化时域 $t \in [t_b - N, t_b]$ 内进行迭代运算的次数, N 为选取的优化时域长度; 矩阵 \mathbf{L} 为预先确定的增益矩阵, 使得矩阵 $\mathbf{A}(t) - \mathbf{L}\mathbf{C}(t)$ 的特征根在单位圆内; $\mathbf{h}_k(t)$ 为在一个优化时域内第 k 次迭代运算后故障跟踪估计器的输出 $\hat{\mathbf{y}}_k(t)$ 和系统实际输出 $\mathbf{y}(t)$ 的差, 即残差; $\hat{\mathbf{f}}(t)$ 是引入的一个可调参数, 称为虚拟故障, 它可以通过离散迭代学习算法加以修正; $\hat{\mathbf{f}}_k(t)$ 为在一个优化时域内进行了第 k 次迭代运算后虚拟故障的大小; $\mathbf{K}(t)$ 为学习增益矩阵; ε 为给定的性能指标. 式(7)是虚拟故障 $\hat{\mathbf{f}}(t)$ 的迭代学习算法. 式(8)表示在跟踪误差满足 $\|\mathbf{y}(t) - \hat{\mathbf{y}}_k(t)\|_\infty > \varepsilon$ 的条件下, 故障跟踪估计器启动计算虚拟故障.

本文的设计思想是: 在系统(1)和(2)没有发生故障的情况下, 系统(3)和(4)中观测出的系统状态 $\hat{\mathbf{x}}(t)$ 和系统输出 $\hat{\mathbf{y}}(t)$ 分别等于系统实际运行时的状态 $\mathbf{x}(t)$ 和输出 $\mathbf{y}(t)$; 在系统发生故障的情况下, 系统(3)和(4)中观测出的系统状态和输出将偏离实际系统运行时的真实值, 于是启动迭代学习算法(7), 在一个优化时域内反复进行迭代学习运算, 修正引入的虚拟故障 $\hat{\mathbf{f}}_k(t)$, 直至使系统(3)和(4)的输出与系统(1)和(2)的实际输出满足式(8), 此时虚拟故障 $\hat{\mathbf{f}}(t)$ 也逼近了系统中实际发生的故障 $\mathbf{f}(t)$, 从而达到了故障诊断的目的. 在以后的优化时域内重复进行同样的优化算法, 即每间隔 N 个时间单位进行一次这样的迭代运算.

1.2 算法收敛性分析

不失一般性, 假设优化时域周期为 $[0, t_b]$, 优化时域长度为 N . 如果系统(1)和(2)的初始状态已知, 则在优化时域周期内, 令故障跟踪估计器的状态和输出的迭代计算初始值分别为 $\hat{\mathbf{x}}_k(0) = \mathbf{x}(0)$, $\hat{\mathbf{y}}_k(0) = \mathbf{y}(0)$, $k = 0, 1, 2, \dots$. 这样, 如下定理成立.

定理 1 考虑系统(1)和(2), 若系统满足假设 1 ~ 假设 3, 设计如式(3)~(8)所示的离散故障跟踪估计器, 满足条件:

1) $\|I - K(t)C(t+1)B_f(t)\| \leq \rho < 1, 0 \leq t \leq t_b$;

2) 初始状态 $\hat{x}_k(0) = x(0), k = 0, 1, \dots$.

则学习律 (7) 使得离散故障跟踪估计器的输出一致收敛于系统的实际输出, 即当 $k \rightarrow \infty$ 时, $\hat{y}_k(t) \rightarrow y(t), 0 \leq t \leq t_b + 1$.

证明 根据式 (5) 和故障调节误差, 由式 (1) 减去 (3) 得

$$\begin{aligned} x(t+1) - \hat{x}_k(t+1) &= \tilde{x}_k(t+1) = \\ & (A(t) - LC(t))\tilde{x}_k(t) + B_f(t)\tilde{f}_k(t). \end{aligned} \quad (9)$$

将式 (9) 的初态记为 $\tilde{x}_k(0)$, 输入记为 $\tilde{f}_k(t)$, 当 $0 \leq t \leq t_b$ 时, 式 (9) 的解可写为

$$\tilde{x}_k(t) = \Phi(t, 0)\tilde{x}_k(0) + \sum_{s=0}^{t-1} \Phi(t, s+1)B_f(s)\tilde{f}_k(s). \quad (10)$$

其中: $0 \leq t \leq t_b + 1, \Phi(t, s)$ 是由式 (9) 中 $A(t) - LC(t)$ 确定的状态转移矩阵.

又由定理中的条件 2) 可知 $\tilde{x}_k(0) = 0$, 因此式 (10) 简化为

$$\tilde{x}_k(t) = \sum_{s=0}^{t-1} \Phi(t, s+1)B_f(s)\tilde{f}_k(s). \quad (11)$$

根据式 (7) 可得

$$\tilde{f}_{k+1}(t) = \tilde{f}_k(t) - K(t)h_k(t+1). \quad (12)$$

由式 (6) 得 $h_k(t+1) = C(t+1)\tilde{x}_k(t+1)$, 代入式 (12) 得

$$\begin{aligned} \tilde{f}_{k+1}(t) &= \tilde{f}_k(t) - K(t)C(t+1)\tilde{x}_k(t+1) = \\ & \tilde{f}_k(t) - K(t)C(t+1)[x(t+1) - \hat{x}_k(t+1)] = \\ & \tilde{f}_k(t) - K(t)C(t+1)[A(t)x(t) + B(t)u(t) + \\ & B_f(t)f(t) - A(t)\hat{x}_k(t) - B(t)u(t) - B_f(t)\hat{f}_k(t)] = \\ & \tilde{f}_k(t) - K(t)C(t+1)[A(t)\tilde{x}_k(t) + B_f(t)\tilde{f}_k(t)] = \\ & [I - K(t)C(t+1)B_f(t)]\tilde{f}_k(t) - \\ & K(t)C(t+1)A(t)\tilde{x}_k(t), \end{aligned} \quad (13)$$

其中 $0 \leq t \leq t_b$. 将式 (11) 代入 (13), 两端取范数得

$$\begin{aligned} \|\tilde{f}_{k+1}(t)\| &\leq \\ \|I - K(t)C(t+1)B_f(t)\| \|\tilde{f}_k(t)\| &+ \\ \|K(t)C(t+1)A(t)\| \sum_{s=0}^{t-1} \|\Phi(t, s+1)B_f(s)\| \|\tilde{f}_k(s)\| &\leq \\ \rho \|\tilde{f}_k(t)\| + b_1 b_2 \sum_{s=0}^{t-1} \|\tilde{f}_k(s)\|. \end{aligned} \quad (14)$$

其中

$$\begin{aligned} 1 &\leq t \leq t_b, \\ b_1 &= \sup_{0 \leq t \leq t_b} \|K(t)C(t+1)A(t)\|, \end{aligned}$$

$$b_2 = \sup_{0 \leq t \leq t_b, 0 \leq s \leq t-1} \|\Phi(t, s+1)B_f(s)\|.$$

式 (14) 两端同乘 $\lambda^t (0 < \lambda < 1)$, 可得

$$\begin{aligned} \lambda^t \|\tilde{f}_{k+1}(t)\| &\leq \\ \rho \lambda^t \|\tilde{f}_k(t)\| + b_1 b_2 \sum_{s=0}^{t-1} \lambda^{t-s} \lambda^s \|\tilde{f}_k(s)\| &\leq \\ \rho \lambda^t \|\tilde{f}_k(t)\| + b_1 b_2 \sum_{s=0}^{t-1} \lambda^{t-s} \sup_{0 \leq \tau \leq t_b} \{\lambda^\tau \|\tilde{f}_k(\tau)\|\} &\leq \\ \rho \lambda^t \|\tilde{f}_k(t)\| + b_1 b_2 \sum_{s=0}^{t-1} \lambda^{t-s} \|\tilde{f}_k\|_\lambda &\leq \\ \rho \lambda^t \|\tilde{f}_k(t)\| + b_1 b_2 \frac{\lambda(1 - \lambda^{t_b})}{1 - \lambda} \|\tilde{f}_k\|_\lambda, \end{aligned} \quad (15)$$

其中 $1 \leq t \leq t_b$. 由式 (13) 和定理 1 中条件 2) 可知, 式 (15) 对 $t = 0$ 也成立. 因此, 根据 λ 范数的定义有

$$\|\tilde{f}_{k+1}\|_\lambda \leq \bar{\rho} \|\tilde{f}_k\|_\lambda, \quad \bar{\rho} = \rho + b_1 b_2 \frac{\lambda(1 - \lambda^{t_b})}{1 - \lambda}. \quad (16)$$

显然, 由 $\rho < 1$ 可找到足够小的 λ 使得 $\bar{\rho} < 1$, 因此 $\lim_{k \rightarrow \infty} \|\tilde{f}_k\|_\lambda = 0$. 又根据式 (6) 和 (11) 可知, 对于 $0 < \lambda < 1$ 有

$$\begin{aligned} \lambda^t \|h_k(t)\| &\leq \\ \|C(t)\| \sum_{s=0}^{t-1} \|\Phi(t, s+1)B_f(s)\| \lambda^{t-s} \lambda^s \|\tilde{f}_k(s)\| &\leq \\ c b_2 \sum_{s=0}^{t-1} \lambda^{t-s} \|\tilde{f}_k\|_\lambda &\leq c b_2 \frac{\lambda(1 - \lambda^{t_b})}{1 - \lambda} \|\tilde{f}_k\|_\lambda. \end{aligned} \quad (17)$$

其中: $1 \leq t \leq t_b + 1, c = \sup_{0 \leq t \leq t_b + 1} \|C(t)\|$.

根据 λ 范数的定义得到

$$\sup_{1 \leq t \leq t_b + 1} \{\lambda^t \|h_k(t)\|\} \leq c b_2 \frac{\lambda(1 - \lambda^{t_b})}{1 - \lambda} \|\tilde{f}_k\|_\lambda, \quad (18)$$

因此, $\lim_{k \rightarrow \infty} \sup_{1 \leq t \leq t_b + 1} \{\lambda^t \|h_k(t)\|\} = 0$. \square

注 2 定理给出了在区间 $0 \leq t \leq t_b + 1$ 上输出误差的收敛性, 这里考虑区间 $0 \leq t \leq t_b$ 上而不是区间 $0 \leq t \leq t_b - 1$ 的学习律是为了与 λ 范数的定义相吻合.

注 3 从收敛性分析中可以看出, $\bar{\rho}$ 的大小决定了跟踪误差趋向于零的快慢程度, 即 $\bar{\rho} (\bar{\rho} < 1)$ 越小, 跟踪误差趋向于零的速度越快, 将 $\bar{\rho} (\bar{\rho} < 1)$ 称为收敛因子. 在实际工程中, 可以适当选取学习增益矩阵使 $\bar{\rho}$ 足够小, 同时由于 CPU 处理速度的提升, 在系统进行采样的时间间隔内, 完全可以进行数百次的迭代运算. 因此, 该方法可以实时在线进行估计系统中发生的故障, 具有重要的理论价值和实际意义.

1.3 虚拟故障分析

由定理 1 的证明过程可以得到如下定理.

定理 2 考虑系统 (1) 和 (2), 若系统满足假设 1 ~ 假设 3, 设计如式 (3)~(8) 所示的离散故障跟踪估计

器, 满足条件:

$$1) \|I - K(t)C(t+1)B_f(t)\| \leq \rho < 1, 0 \leq t \leq t_b;$$

$$2) \text{初始状态 } \hat{x}_k(0) = x(0), k = 0, 1, \dots$$

则当 $k \rightarrow \infty$ 时, $\lim_{k \rightarrow \infty} \|\tilde{f}_k\|_\lambda = 0, 0 \leq t \leq t_b$.

注 4 定理 1 和定理 2 中 k 是优化时域内迭代运算的次数, 在此均给出当 k 趋于无穷时 $h_k(t)$ 和 $\tilde{f}_k(t)$ 趋于零, 这是故障跟踪估计器的输出完全跟踪系统实际输出的一种极限情况. 在实际工程中, 迭代运算使得估计器输出 $\hat{y}_k(t)$ 与系统实际输出 $y(t)$ 在优化时域内满足式 (8), 即如果跟踪误差小于给定的跟踪误差 ε , 或者迭代次数超过最大迭代次数 n , 则停止运算, 等待在下一个优化时域内进行迭代运算.

2 仿真研究

为了验证该算法的有效性, 考虑如下一类含有故障的离散线性时变系统:

$$x_1(t+1) = 0.2x_1(t), \quad (19)$$

$$x_2(t+1) = -0.25x_1(t) + 0.0015tx_2(t) + u(t) + f(t), \quad (20)$$

$$y(t) = -0.2x_1(t) + x_2(t). \quad (21)$$

选取系统中的参数为: 允许跟踪误差 $\varepsilon = 0.05$, 优化时域长度 $N = 10$, 迭代算法增益矩阵 $k = 0.4$, 满足 $\rho = 0.6 < 1$ 的收敛条件, 增益矩阵 $L = [0.5, 0]^T$. 利用所设计的离散故障跟踪估计器, 估计系统中发生的故障信号. 假设故障函数分别为方波函数、指数函数、正弦函数. 函数形式如下:

$$f_1(t) = \begin{cases} 4, & 5 \leq t \leq 35, 65 \leq t \leq 95; \\ 0, & \text{otherwise.} \end{cases} \quad (22)$$

$$f_2(t) = \begin{cases} e^{0.02t}, & 15 \leq t \leq 85; \\ 0, & \text{otherwise.} \end{cases} \quad (23)$$

$$f_3(t) = \begin{cases} \sin(0.2(t-5)), & 5 \leq t \leq 67; \\ 0, & \text{otherwise.} \end{cases} \quad (24)$$

仿真结果如图 1~图 3 所示. 由仿真结果可见, 本文所设计的离散故障跟踪估计器不但可以检测出离散线性时变系统中各种不同类型的故障信号, 而且可以对故障信号进行精确估计.




图 1 方波函数故障估计曲线




图 2 指数函数故障估计曲线




图 3 正弦函数故障估计曲线

3 结 论

针对一类含有故障的离散线性时变系统, 将迭代学习策略应用到故障诊断中, 给出了算法收敛的范数形式的充分条件. 该算法不仅可以有效地检测系统故障, 还可以实现对故障信号的精确估计, 而且针对不同类型的故障具有很好的适应性. 同时基于迭代学习的离散故障跟踪估计器更为直接, 便于工程实现.

参考文献(References)

- [1] Ding X, Guo L, Jeinsch T. A characterization of parity space and its application to robust fault detection[J]. IEEE Trans on Automatic Control, 1999, 44(2): 337-343.
- [2] Zhong M Y, Ye H, Ding S X, et al. Observer-based fast rate fault detection for a class of multirate sampled-data systems[J]. IEEE Trans on Automatic Control, 2007, 52(3): 520-525.
- [3] 陈楚瑶, 朱大奇. 神经网络主元分析的传感器故障诊断方法[J]. 系统工程与电子技术, 2010, 32(7): 1549-1552. (Chen C Y, Zhu D Q. Sensor fault diagnosis method based on neural network principal component analysis[J]. Systems Engineering and Electronics, 2010, 32(7): 1549-1552.)
- [4] 陈明, 童朝南, 张士勇. 一类仿射型非线性系统智能故障诊断[J]. 控制与决策, 2011, 26(2): 221-226. (Chen M, Tong C N, Zhang S Y. Intelligent fault diagnosis for a class of affine nonlinear system[J]. Control and Decision, 2011, 26(2): 221-226.)
- [5] Zhang P, Ding S X. Disturbance decoupling in fault detection of linear periodic systems[J]. Automatica, 2007, 43(8): 1410-1417.