

控制与决策

Control and Decision

基于正交超平面空间定向扩展的滤波故障诊断方法

王子赟, 程林, 王艳, 纪志成

引用本文:

王子赟,程林,王艳,纪志成. 基于正交超平面空间定向扩展的滤波故障诊断方法[J]. *控制与决策*, 2022, 37(12): 3223–3232.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.1090>

您可能感兴趣的其他文章

Articles you may be interested in

[基于超平行空间集员滤波的非线性系统状态估计方法](#)

Hyperparallel space set-membership filtering based state estimation algorithm for nonlinear system

控制与决策. 2022, 37(9): 2287–2295 <https://doi.org/10.13195/j.kzyjc.2021.0015>

[基于多胞体双重滤波的系统状态估计方法](#)

Orthotopic double filtering based state estimation algorithm

控制与决策. 2022, 37(1): 127–134 <https://doi.org/10.13195/j.kzyjc.2020.0968>

[基于广义主成分分析的重构故障子空间建模方法](#)

Reconstructed fault subspace modelling method based on generalized principal component analysis

控制与决策. 2021, 36(4): 808–814 <https://doi.org/10.13195/j.kzyjc.2019.0818>

[基于向量集逆区间滤波的故障观测器设计](#)

Vector set inversion interval filtering based fault observer design

控制与决策. 2021, 36(12): 2973–2981 <https://doi.org/10.13195/j.kzyjc.2020.0212>

[标签Petri网的路径信息在故障诊断中的应用](#)

Application of path information of labeled Petri nets in fault diagnosis

控制与决策. 2021, 36(2): 325–334 <https://doi.org/10.13195/j.kzyjc.2019.0698>

基于正交超平行空间定向扩展的滤波故障诊断方法

王子赞^{1,2}, 程林², 王艳^{2†}, 纪志成²

(1. 江南大学轻工过程先进控制教育部重点实验室, 江苏无锡 214122;
2. 江南大学物联网技术应用教育部工程研究中心, 江苏无锡 214122)

摘要: 针对含有未知但有界噪声的离散系统故障诊断问题, 提出基于正交超平行空间定向扩展的滤波故障诊断方法. 首先, 在传统超平行空间的结构基础上, 利用相邻时刻超平行空间顶点极值定义正交超平行空间, 包裹参数可行集的上下界的同时, 保证参数边界值的单调收敛; 随后, 利用超平行空间与带空间的交集情况, 检测系统是否发生故障, 进而在故障发生时定向扩展正交超平行空间, 依据带空间与正交超平行空间在扩展方向测试集的交集情况实现故障隔离; 最后, 利用正交超平行空间在迭代过程中的收缩性质完成故障识别. 给出的仿真示例验证了算法的可行性和有效性.

关键词: 故障诊断; 正交超平行空间; 定向扩展; 滤波

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2021.1090

开放科学(资源服务)标识码(OSID):



引用格式: 王子赞, 程林, 王艳, 等. 基于正交超平行空间定向扩展的滤波故障诊断方法 [J]. 控制与决策, 2022, 37(12): 3223-3232.

Orthometric hyperparallel spatial directional expansion filtering based fault diagnosis method

WANG Zi-yun^{1,2}, CHENG Lin², WANG Yan^{2†}, JI Zhi-cheng²

(1. Key Laboratory of Advanced Process Control for Light Industry of Ministry of Education, Jiangnan University, Wuxi 214122, China; 2. Engineering Research Center of Internet of Things Technology Applications of Ministry of Education, Jiangnan University, Wuxi 214122, China)

Abstract: An orthometric hyperparallel spatial directional expansion filtering based fault diagnosis method is proposed for discrete systems with unknown but bounded noises. Firstly, the orthometric hyperparallel space is defined by the extremum of the parallelotope at the adjacent time based on the spatial structure of traditional parallelotope, to wrap the upper and lower bounds of the feasible parameter set and guarantee the monotonic convergence of the parameter boundary value. Then, whether the system is faulty is checked by detecting the intersection of the parallelotopic space and the strip space, and then the orthometric hyperparallel space is extended directionally at the time of fault occurrence, and the fault isolation is realized according to the intersection of the extended orthometric hyperparallel space and the strip space. Finally, the fault identification is completed by the shrinkage property of the orthometric hyperparallel space in the iterative process. The simulations are given to verify the feasibility and effectiveness of the proposed algorithm.

Keywords: fault diagnosis; orthometric hyperparallel space; directional expansion; filtering

0 引言

随着科学与技术的飞速发展, 现代化复杂工程系统规模越来越大, 例如动力系统工程^[1]、冶金石化工业^[2]和电网系统^[3]等, 这些现代工业的特点是大型化、集成化、自动化, 对设备依赖程度高, 因此及时快速地对工业系统进行故障诊断至关重要^[4-6]. 故障诊断主要分为故障检测、故障隔离和故障识别 3 个环

节^[7]. 目前故障诊断的方法大体可分为 3 类: 基于模型的方法^[8]、基于信号处理的方法^[9]和基于知识的方法^[10]. 其中: 基于信号处理的故障诊断依据是对历史信号的处理, 得到与故障相关的信号特征进行故障诊断, 但其缺点是对早期潜在的故障无效, 只有当故障发生到一定程度并影响到外部特征时才有效, 且多数情况下无法定位故障; 基于知识的故障诊断

收稿日期: 2021-06-23; 录用日期: 2021-08-09.

基金项目: 国家重点研发计划项目(2020YFB1710600); 国家自然科学基金项目(61802150, 61973138); 江苏省科协青年科技人才托举工程项目(TJ-2021-006).

责任编辑: 魏秀琨.

†通讯作者. E-mail: yanwang@jiangnan.edu.cn.

方法是专家凭借相关经验知识,通过被诊断对象的自身信息进行故障诊断,其缺点是对相关的专业知识和经验过于依赖;基于模型的故障诊断方法原理是利用输入输出量构造残差信号来进行故障诊断,在模型已知的情况下可以取得更为精确的诊断效果.同时,设备在生产时不可避免地会受到噪声和干扰的影响,传统的基于模型的故障诊断方法要求输入噪声和干扰必须满足一定的分布规律,例如高斯分布^[11]等.然而,很多实际工程领域的噪声和干扰的概率分布的先验知识一般很难满足假定条件,限制了这些基于噪声概率分析策略的有效性.集员滤波仅限定系统的噪声未知但有界,这一点在很多实际工程系统中都可以满足^[12],因此集员滤波方法具有更好的实用性,从而使得集员滤波在故障诊断、鲁棒控制和模式识别等领域具有广泛的应用^[13-15].

集员滤波算法就是将系统的噪声限定在有界的范围内,通过系统的模型和可量测的输入输出数据将系统的真值限定在一个可行集内,这个可行集里面的解都可以作为参数估计的可行解,因此如何描述可行集的复杂形状是集员滤波估计的关键,不同的空间描述方法将会在保守性与计算复杂性之间取舍,常用来描述可行集的方法包括椭球^[16-18]、全对称多胞体^[19-20]、多面体^[21]和正多胞体^[22-23]等.椭球算法计算简单,但保守性较强,容易造成较大的空间冗余度;全对称多胞体的保守性虽然降低但是其随迭代次数的增加,容易导致多胞空间维数的增大,进而使计算复杂度增加;多面体的形状不规则,凸优化过程也将带来形状矩阵维数的增加;正多胞体计算较为简单,但其保守性也较强.目前,大多数基于集员滤波的故障诊断的研究都是集中在故障检测,针对故障隔离和故障辨识的研究相对较少,而且大多数的研究成果都集中在基于椭球的故障诊断方法. Zhou等^[24]提出了一种椭球边界集员辨识算法,给出了包含真实参数值的故障参数保证集,通过在识别过程中获得的预测参数与观测参数集之间的一致性检查,可以检测和隔离由参数突变引起的故障; Reppa等^[25]利用椭球包裹真实参数值,通过检测椭球和测量带是否有交集判断有无故障发生,故障发生后将椭球全局扩展并与测量带更新完成故障隔离,数值仿真分析结果验证了所提出算法的有效性.椭球虽然计算相对简单,但却带来了保守性较强、空间冗余度高的缺点,没有太大的实用性.

本文旨在提出一种基于正交超平行空间定向扩展的滤波故障诊断方法,首先定义超平行空间用于

包裹参数可行集,降低传统的多面体计算带来的复杂度,减少计算量,随后利用正交超平行空间求解当前时刻的几何空间,保证参数边界值的单调收敛,相较于椭球而言,可以更加贴合实际系统参数可行集,降低保守性和空间冗余度.进而,通过检测参数可行集是否为空来完成故障检测,当可行集为空时系统发生故障,由超平行空间测试集的状态隔离出具体发生故障的参数,当隔离出故障参数后,经过定向扩展得到故障状态下包裹故障参数的正交超平行空间,完成故障识别.

1 预备知识

首先定义本文使用的一些符号.上标 T 表示向量或矩阵的转置; $[a, b]$ 表示区间且 $a \leq b$; $[a_1, a_2, \dots, a_n] \in R^n$ 表示 n 维向量;若 $d \in R^n$,则 $\text{diag}\{d\}$ 表示对角值等于 d 的对角阵; $|\cdot|$ 表示绝对值; R^+ 表示正实数; $\|\cdot\|_\infty$ 表示无穷范数; \max 表示取最大值; \min 表示取最小值; $\mathbf{0}_n$ 表示 n 维零向量; Δ 表示变化量; \cap 表示交集.

定义 n 维的带空间为

$$S(\mathbf{p}, c) = \{\boldsymbol{\theta} : |\mathbf{p}^T \boldsymbol{\theta} - c| \leq 1\}, \mathbf{p} \in R^n. \quad (1)$$

事实上,任何一个包含真值紧密结合的多面体 \mathcal{V} 都可以由 m 条非平行的 n 维带空间交叉形成,其中 $m \geq n$.当 $m = n$ 时,该多面体为超平行空间,即

$$\mathcal{P} = \bigcap_{i=1}^n S(\mathbf{p}_i, c_i). \quad (2)$$

对于 n 维超平行空间 \mathcal{P} 而言, $\mathbf{P} = [\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_n]^T \in R^{n \times n}$,其中 \mathbf{P} 是可逆的. \mathcal{P} 的另外一种表达式^[26]为

$$\mathcal{P} = \{\boldsymbol{\theta} : \|\mathbf{P}(\boldsymbol{\theta} - \boldsymbol{\theta}_c)\|_\infty \leq 1\}. \quad (3)$$

其中

$$\mathbf{P} = [\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_n]^T \in R^{n \times n}, \quad (4)$$

$$\boldsymbol{\theta}_c = \mathbf{P}^{-1}[c_1, c_2, \dots, c_n]^T \in R^n. \quad (5)$$

定义 $\mathbf{T} = \mathbf{P}^{-1}$,式(3)可转化为^[26]

$$\mathcal{P}(\mathbf{T}, \boldsymbol{\theta}_c) = \{\boldsymbol{\theta} : \boldsymbol{\theta} = \boldsymbol{\theta}_c + \mathbf{T}\tilde{\boldsymbol{\theta}}, \|\tilde{\boldsymbol{\theta}}\|_\infty \leq 1\}. \quad (6)$$

其中: $\boldsymbol{\theta}_c$ 为超平行空间的中心, \mathbf{T} 为超平行空间的生成矩阵.

2 问题描述

考虑如下线性递归模型:

$$y(k) = \boldsymbol{\varphi}^T(k)(\boldsymbol{\theta}_o + \Delta\boldsymbol{\theta}_{f_a}(k)) + e(k). \quad (7)$$

其中: $k = 1, 2, \dots, N$, N 为总采样长度; $\boldsymbol{\varphi}(k) \in R^n$ 为可观测的数据向量; $y(k)$ 为系统的输出数据; $\boldsymbol{\theta}_o$ 为

无故障状态下的系统参数真值; $\Delta\theta_{f_a}(k)$ 为 k 时刻故障发生时的参数变化向量, f_a 为参数的故障类型, 假定 $k = 0$ 时, $f_a = f_0, \Delta\theta_{f_0}(k) = \mathbf{0}_n$, 即系统处于正常状态; $\theta_o + \Delta\theta_{f_a}(k) \in R^n$ 为待估计的参数向量, 为了方便后面的描述, 令 $\theta_{f_a}(k) = \theta_o + \Delta\theta_{f_a}(k)$; $e(k)$ 定义为 k 时刻未知但有界的噪声, 噪声信号幅值为 $\delta(k)$, 即 $|e(k)| \leq \delta(k), \delta(k) \in R^+$.

当系统在 k 时发生故障, $\Delta\theta_{f_a}(k)$ 会发生变化, 此时未知变化是有界的, 给定 $\gamma^{\max} = [\gamma_1^{\max}, \gamma_2^{\max}, \dots, \gamma_n^{\max}]^T$, 即^[27]

$$|\Delta\theta_{f_a}(k)| \leq \gamma^{\max}, \forall k. \quad (8)$$

在 k 时刻的测量集合 $S(k)$ 可表示为

$$S(k) = \{\theta : |y(k) - \varphi^T(k)\theta| \leq \delta(k)\}. \quad (9)$$

式(9)可转换为如式(1)所示的带空间, 即

$$S(\mathbf{p}_k, c_k) = \{\theta : |\mathbf{p}_k^T \theta - c_k| \leq 1\}. \quad (10)$$

其中

$$\mathbf{p}_k = \frac{\varphi(k)}{\delta(k)}, c_k = \frac{y(k)}{\delta(k)}. \quad (11)$$

由式(9)可以看出, k 时刻系统的参数集均在两条相互平行的超平面之间. 因此, 随着采样时间的增加, 在给定的时间内, 所有可能的参数最终被包含在凸空间 $\Theta(k)$ 内, 即

$$\begin{aligned} \Theta(k) = & \\ & \{\theta : |y(k) - \varphi^T(k)\theta| \leq \delta(k), k = 1, 2, \dots, N\} = \\ & \bigcap_{k=1}^N S(k) = \Theta(k-1) \cap S(k). \end{aligned} \quad (12)$$

随着采样时间的增加, 式(12)所示的凸空间结构复杂性不断增加. 本文的目的在于, 针对线性递归系统(7)的故障诊断问题, 考虑未知但有界噪声的影响, 提出一种基于正交超平行空间定向扩展的滤波故障诊断方法.

3 基于正交超平行空间定向扩展的滤波故障诊断

引理1 给定 n 维超平行空间 $\mathcal{P}(\mathbf{T}_{k-1}, \theta_{c,k-1})$ 与测量带 $S(\mathbf{p}_k, c_k)$ 相交, 令超平行空间生成矩阵中的每一列向量为 $\mathbf{t}_{k-1,i}$, 其中 $i = 1, 2, \dots, n$, 且满足 $\mathbf{p}_k^T \mathbf{t}_{k-1,i} \geq 0$ 成立, 若不成立, 则令 $\mathbf{t}_{k-1,i} = -\mathbf{t}_{k-1,i}$, 存在包裹相交区域的最小体积的 n 维超平行空间 $\mathcal{P}(\mathbf{T}_k, \theta_{c,k})$ ^[26], 即

$$\mathcal{P}(\mathbf{T}_k, \theta_{c,k}) = \begin{cases} \bar{\mathcal{P}}(\bar{\mathbf{T}}, \bar{\theta}_c), & i^* = 0; \\ \mathcal{P}^*(\mathbf{T}^*, \theta_c^*), & i^* \neq 0. \end{cases} \quad (13)$$

其中

$$i^* = \arg \max_{b=0,1,\dots,n} \bar{\mathbf{p}}_k^T \bar{\mathbf{t}}_b, \bar{\mathbf{t}}_0 = \bar{\mathbf{p}}_k / |\bar{\mathbf{p}}_k|^2. \quad (14)$$

$$\bar{\theta}_c = \theta_{c,k-1} + \sum_{i=1}^n \frac{r_i^+ - r_i^-}{2} \mathbf{t}_{k-1,i}. \quad (15)$$

$$\bar{\mathbf{t}}_i = \frac{r_i^+ + r_i^-}{2} \mathbf{t}_{k-1,i}. \quad (16)$$

$$\theta_c^* = \bar{\theta}_c + \frac{1}{\bar{\mathbf{p}}_k^T \bar{\mathbf{t}}_{i^*}} (\bar{c}_k - \bar{\mathbf{p}}_k^T \bar{\theta}_c). \quad (17)$$

$$\mathbf{t}_i^* = \begin{cases} \bar{\mathbf{t}}_i - \frac{\bar{\mathbf{p}}_k^T \bar{\mathbf{t}}_i}{\bar{\mathbf{p}}_k^T \bar{\mathbf{t}}_{i^*}} \bar{\mathbf{t}}_{i^*}, & i \neq i^*; \\ \frac{1}{\bar{\mathbf{p}}_k^T \bar{\mathbf{t}}_{i^*}} \bar{\mathbf{t}}_{i^*}, & i = i^*. \end{cases} \quad (18)$$

式(14)~(18)中, 有

$$\bar{\mathbf{p}}_k = \frac{2}{r_0^+ + r_0^-} \mathbf{p}_k. \quad (19)$$

$$\bar{c}_k = \frac{2}{r_0^+ + r_0^-} \left(c_k + \frac{r_0^+ - r_0^-}{2} \right). \quad (20)$$

$$r_i^\pm = \begin{cases} \min \left(1, \frac{1 \mp \epsilon_0^\pm}{\mathbf{p}_k^T \mathbf{t}_{k-1,i}} - 1 \right), & \mathbf{p}_k^T \mathbf{t}_{k-1,i} \neq 0; \\ 1, & \mathbf{p}_k^T \mathbf{t}_{k-1,i} = 0. \end{cases} \quad (21)$$

其中: $r_0^+ = \min(1, \epsilon_0^+), r_0^- = \min(1, -\epsilon_0^-), \epsilon_0^+$ 和 ϵ_0^- 为标量, 且有

$$\begin{cases} \epsilon_0^+ = (\mathbf{p}_k^T \theta_{c,k-1} - c_k) + \sum_{i=1}^n \mathbf{p}_k^T \mathbf{t}_{k-1,i}, \\ \epsilon_0^- = (\mathbf{p}_k^T \theta_{c,k-1} - c_k) - \sum_{i=1}^n \mathbf{p}_k^T \mathbf{t}_{k-1,i}. \end{cases} \quad (22)$$

根据引理1可求得 k 时刻包裹参数可行集的最小体积的超平行空间 $\mathcal{P}(\mathbf{T}_k, \theta_{c,k})$. 定义 n 维超平行空间生成矩阵 \mathbf{T} 的每一列为 \mathbf{t}_i , 其中 $i = 1, 2, \dots, n$, 由式(6)的表达式可以计算出超平行空间的顶点 \mathbf{V}_l , 即

$$\mathbf{V}_l = \theta_c + \sum_{i=1}^n \alpha_{l,i} \mathbf{t}_i \in R^n. \quad (23)$$

其中: $l = 1, 2, \dots, 2^n, \alpha_{l,i} \in \{-1, 1\}$.

定义 $\mathbf{V}_k = [\mathbf{V}_1, \mathbf{V}_2, \dots, \mathbf{V}_{2^n}] \in R^{n \times 2^n}$ 为 k 时刻 n 维超平行空间的顶点矩阵, $\mathbf{V}_k(c, l)$ 为 \mathbf{V}_k 矩阵第 l 列的第 c 个元素, $c = 1, 2, \dots, n$. 由式(23)可求出 k 时刻每个参数的最大值 $\theta_c^+(k)$ 和最小值 $\theta_c^-(k)$, 即

$$\begin{cases} \theta_c^+(k) = \max(\mathbf{V}_k(c, l)), \\ \theta_c^-(k) = \min(\mathbf{V}_k(c, l)). \end{cases} \quad (24)$$

然而随着采样时间的增加, 难以保证 $\mathcal{P}(\mathbf{T}_k, \theta_{c,k})$ 的参数边界值单调收敛. 为解决这一问题, 本文定义 k 时刻的正交超平行空间 $\mathcal{P}_o(\mathbf{T}_k, \theta_{c,k})$ 为

$$\mathcal{P}_o(\mathbf{T}_k, \boldsymbol{\theta}_{c,k}) = \{\boldsymbol{\theta} : \boldsymbol{\theta} = \boldsymbol{\theta}_{c,k} + \mathbf{T}_k \tilde{\boldsymbol{\theta}}, \|\tilde{\boldsymbol{\theta}}\|_\infty \leq 1\}. \quad (25)$$

其中

$$\boldsymbol{\theta}_{c,k} = \begin{bmatrix} \frac{\theta_{o_1}^+(k) + \theta_{o_1}^-(k)}{2} \\ \vdots \\ \frac{\theta_{o_n}^+(k) + \theta_{o_n}^-(k)}{2} \end{bmatrix}, \quad \mathbf{T}_k = \text{diag} \left\{ \frac{\theta_{o_1}^+(k) - \theta_{o_1}^-(k)}{2}, \dots, \frac{\theta_{o_n}^+(k) - \theta_{o_n}^-(k)}{2} \right\}. \quad (26)$$

$$\begin{cases} \theta_{o_u}^+(k) = \min(\theta_{o_u}^+(k-1), \theta_{o_u}^+(k)), \\ \theta_{o_u}^-(k) = \max(\theta_{o_u}^-(k-1), \theta_{o_u}^-(k)). \end{cases} \quad (27)$$

这里 $u = 1, 2, \dots, n$. 由式(25)~(27)可知, k 时刻的正交超平行空间是将 k 时刻的超平行空间与 $k-1$ 时刻的正交超平行空间的参数边界最大值对比取最小, 参数边界最小值对比取最大, 从而保证了 $\mathcal{P}_o(\mathbf{T}_k, \boldsymbol{\theta}_{c,k}) \subseteq \mathcal{P}_o(\mathbf{T}_{k-1}, \boldsymbol{\theta}_{c,k-1})$. 本文利用式(13)求得每个时刻包裹参数可行集的最小体积的超平行空间, 再由式(23)~(27)求出每个时刻的正交超平行空间, 以正交超平行空间的边界值作为包裹真值的上下界, 保证了参数边界值的单调收敛, 使包裹真值的可行集更加紧密, 同时针对故障状态, 设计基于正交超平行空间定向扩展的故障诊断策略.

3.1 故障检测

引理2 当标量 $\epsilon_0^+ < -1$ 或者 $\epsilon_0^- > 1$ 时, 超平行空间 $\mathcal{P}(\mathbf{T}_{k-1}, \boldsymbol{\theta}_{c,k-1})$ 与测量带 $S(\mathbf{p}_k, c_k)$ 不相交^[26,28].

故障检测是基于对超平行空间 $\mathcal{P}(\mathbf{T}_{k-1}, \boldsymbol{\theta}_{c,k-1})$ 和测量带 $S(\mathbf{p}_k, c_k)$ 的一致性分析, 即当 $\mathcal{P}(\mathbf{T}_{k-1}, \boldsymbol{\theta}_{c,k-1}) \cap S(\mathbf{p}_k, c_k) = \emptyset$ 时, 系统发生故障, 因此由引理2可知, 当式(22)中的标量满足 $\epsilon_0^+ < -1$ 或者 $\epsilon_0^- > 1$ 时, 可判定故障发生.

3.2 故障隔离和识别

假设在 k 时刻, 系统检测到故障, 定向扩展 $\mathcal{P}_o(\mathbf{T}_{k-1}, \boldsymbol{\theta}_{c,k-1})$ 获得 n 个正交超平行空间测试集 $\mathcal{P}_{o,d}^t(\mathbf{T}_{k-1}, \boldsymbol{\theta}_{c,k-1})$, 其中 $d = 1, 2, \dots, n$.

定义 n 维正交超平行空间测试集 $\mathcal{P}_{o,d}^t(\mathbf{T}_{k-1}, \boldsymbol{\theta}_{c,k-1})$ 为

$$\mathcal{P}_{o,d}^t(\mathbf{T}_{k-1}, \boldsymbol{\theta}_{c,k-1}) = \{\boldsymbol{\theta} : \boldsymbol{\theta} = \boldsymbol{\theta}_{c,k-1} + \mathbf{T}_{k-1} \tilde{\boldsymbol{\theta}}, \|\tilde{\boldsymbol{\theta}}\|_\infty \leq 1\}. \quad (28)$$

其中

$$\boldsymbol{\theta}_{c,k-1} = \begin{bmatrix} \frac{\theta_{(o,d)_1}^{t+}(k-1) + \theta_{(o,d)_1}^{t-}(k-1)}{2} \\ \vdots \\ \frac{\theta_{(o,d)_n}^{t+}(k-1) + \theta_{(o,d)_n}^{t-}(k-1)}{2} \end{bmatrix}. \quad (29)$$

$$\mathbf{T}_{k-1} = \text{diag} \left\{ \frac{\theta_{(o,d)_1}^{t+}(k-1) - \theta_{(o,d)_1}^{t-}(k-1)}{2}, \dots, \frac{\theta_{(o,d)_n}^{t+}(k-1) - \theta_{(o,d)_n}^{t-}(k-1)}{2} \right\}. \quad (30)$$

1) 当 $p \neq d$ 且 $1 \leq p \leq n$ 时, 有

$$\begin{cases} \theta_{(o,d)_p}^{t+}(k-1) = \theta_{o_p}^+(k-1) + 2\gamma_p^{\max}, \\ \theta_{(o,d)_p}^{t-}(k-1) = \theta_{o_p}^-(k-1) - 2\gamma_p^{\max}. \end{cases} \quad (31)$$

2) 当 $p = d$ 时, 有

$$\begin{cases} \theta_{(o,d)_p}^{t+}(k-1) = \theta_{o_p}^+(k-1), \\ \theta_{(o,d)_p}^{t-}(k-1) = \theta_{o_p}^-(k-1). \end{cases} \quad (32)$$

由式(28)~(32)可知, $\mathcal{P}_{o,d}^t(\mathbf{T}_{k-1}, \boldsymbol{\theta}_{c,k-1})$ 为除第 d 个参数方向外其余 $n-1$ 个参数方向上均扩展的正交超平行空间测试集. 给定时间长度 L , 假定在 k 时刻检测到发生故障后的 L 时刻内无新故障发生, 可获得测量带 $S(\mathbf{p}_k, c_k), S(\mathbf{p}_{k+1}, c_{k+1}), \dots, S(\mathbf{p}_{k+L}, c_{k+L})$. 利用式(13)将定向扩展得到的 n 个正交超平行空间测试集分别与 L 个测量带单独计算, 获得 $k+L$ 时刻的 n 个超平行空间测试集 $\mathcal{P}_d^t(\mathbf{T}_{k+L}, \boldsymbol{\theta}_{c,k+L})$.

定理1 如果 $\mathcal{P}_j^t(\mathbf{T}_{k+L}, \boldsymbol{\theta}_{c,k+L}) = \emptyset$, 其中 $j \in \{1, 2, \dots, n\}$, 说明参数向量的第 j 个组成部分发生故障, 则初始化正交超平行空间 $\mathcal{P}_o^{\text{in}}(\mathbf{T}_k, \boldsymbol{\theta}_{c,k})$ 中的第 j 个组成部分的参数边界定向扩展为

$$\begin{cases} \theta_{o_j}^{\text{in}+}(k) = \theta_{o_j}^+(k-1) + 2\gamma_j^{\max}, \\ \theta_{o_j}^{\text{in}-}(k) = \theta_{o_j}^-(k-1) - 2\gamma_j^{\max}; \end{cases} \quad (33)$$

否则, 如果 $\mathcal{P}_j^t(\mathbf{T}_{k+L}, \boldsymbol{\theta}_{c,k+L}) \neq \emptyset$, 说明参数向量的第 j 个组成部分没有发生故障, 则初始化正交超平行空间 $\mathcal{P}_o^{\text{in}}(\mathbf{T}_k, \boldsymbol{\theta}_{c,k})$ 中的第 j 个组成部分的参数边界无需扩展, 即

$$\begin{cases} \theta_{o_j}^{\text{in}+}(k) = \theta_{o_j}^+(k-1), \\ \theta_{o_j}^{\text{in}-}(k) = \theta_{o_j}^-(k-1). \end{cases} \quad (34)$$

证明 假设参数向量中的第 j 个组成部分发生故障, 则此时的参数向量 $\boldsymbol{\theta}_{f_a}(k)$ 满足

$$\begin{cases} \theta_{f_{a_u}}(k) = \theta_{f_{a-1_u}}(k), \quad u \neq j; \\ \theta_{f_{a_u}}(k) = \theta_{f_{a-1_u}}(k) + \Delta\theta_{f_{a_u}}(k), \quad u = j. \end{cases} \quad (35)$$

其中: $u = 1, 2, \dots, n$. 由式(31)和(32)可以得到

$\mathcal{P}_{o,d}^t(\mathbf{T}_{k-1}, \boldsymbol{\theta}_{c,k-1})$ 为除第 d 个参数方向其余 $n-1$ 个参数方向均扩展的正交超平行空间测试集, 所以 $\mathcal{P}_{o,j}^t(\mathbf{T}_{k-1}, \boldsymbol{\theta}_{c,k-1})$ 为没扩展第 j 个组成部分的正交超平行空间测试集, 即

$$\begin{cases} \theta_{f_{a_j}}(k) \notin \mathcal{P}_{o,j}^t(\mathbf{T}_{k-1}, \boldsymbol{\theta}_{c,k-1}), u=j; \\ \theta_{f_{a_u}}(k) \in \mathcal{P}_{o,j}^t(\mathbf{T}_{k-1}, \boldsymbol{\theta}_{c,k-1}), u \neq j. \end{cases} \quad (36)$$

利用式(13)与 L 个测量带求交集可知

$$\mathcal{P}_j^t(\mathbf{T}_{k+L}, \boldsymbol{\theta}_{c,k+L}) \subseteq \mathcal{P}_{o,j}^t(\mathbf{T}_{k-1}, \boldsymbol{\theta}_{c,k-1}).$$

由于

$$\theta_{f_{a_j}}(k) \notin \mathcal{P}_{o,j}^t(\mathbf{T}_{k-1}, \boldsymbol{\theta}_{c,k-1}), \quad (37)$$

可见

$$\theta_{f_{a_j}}(k) \notin \mathcal{P}_j^t(\mathbf{T}_{k+L}, \boldsymbol{\theta}_{c,k+L}), \quad (38)$$

因此

$$\mathcal{P}_j^t(\mathbf{T}_{k+L}, \boldsymbol{\theta}_{c,k+L}) = \emptyset. \quad (39)$$

此时说明参数向量的第 j 个组成部分发生故障, 则将其参数边界定向扩展为

$$\begin{cases} \theta_{o_j}^{\text{in}+}(k) = \theta_{o_j}^+(k-1) + 2\gamma_j^{\text{max}}, \\ \theta_{o_j}^{\text{in}-}(k) = \theta_{o_j}^-(k-1) - 2\gamma_j^{\text{max}}. \end{cases}$$

其中: γ_j^{max} 为参数向量第 j 个组成部分给定的变化最大值. 反之, 如果 $\mathcal{P}_j^t(\mathbf{T}_{k+L}, \boldsymbol{\theta}_{c,k+L}) \neq \emptyset$ 说明 $\theta_{f_{a_j}}(k) \in \mathcal{P}_j^t(\mathbf{T}_{k+L}, \boldsymbol{\theta}_{c,k+L})$, 则 $\theta_{f_{a_j}}(k) \in \mathcal{P}_{o,j}^t(\mathbf{T}_{k-1}, \boldsymbol{\theta}_{c,k-1})$, 说明参数向量的第 j 个组成成分没有发生故障, 则不将其参数边界定向扩展, 即

$$\begin{cases} \theta_{o_j}^{\text{in}+}(k) = \theta_{o_j}^+(k-1), \\ \theta_{o_j}^{\text{in}-}(k) = \theta_{o_j}^-(k-1). \end{cases} \quad \square$$

以二维空间为例, 图1描述的是 k 时刻发生故障时故障隔离的过程. 在 $k+1$ 时刻, $\mathcal{P}_1^t(k+1) \neq \emptyset$, 而 $\mathcal{P}_2^t(k+1) \neq \emptyset$, 此时无法实现故障隔离; 在 $k+2$ 时刻, $\mathcal{P}_1^t(k+2) = \emptyset$, 而 $\mathcal{P}_2^t(k+2) \neq \emptyset$, 可以判定故障发生在参数 θ_1 , 故障隔离完成.




图1 故障隔离过程

在实现系统故障隔离后, 将 $\mathcal{P}_o(\mathbf{T}_{k-1}, \boldsymbol{\theta}_{c,k-1})$ 定向扩展得到初始化正交超平行空间 $\mathcal{P}_o^{\text{in}}(\mathbf{T}_k, \boldsymbol{\theta}_{c,k})$.

定理2 如果 $\theta_{f_{a-1}}(k)$ 在正交超平行空间 $\mathcal{P}_o(\mathbf{T}_{k-1}, \boldsymbol{\theta}_{c,k-1})$ 里, 此时在 k 时刻参数向量的第 j 个组成部分发生故障, 则新的故障参数值 $\theta_{f_a}(k)$ 将会在初始化正交超平行空间 $\mathcal{P}_o^{\text{in}}(\mathbf{T}_k, \boldsymbol{\theta}_{c,k})$ 中, 即

$$\mathcal{P}_o^{\text{in}}(\mathbf{T}_k, \boldsymbol{\theta}_{c,k}) = \{\boldsymbol{\theta} : \boldsymbol{\theta} = \boldsymbol{\theta}_{c,k} + \mathbf{T}_k \tilde{\boldsymbol{\theta}}, \|\tilde{\boldsymbol{\theta}}\|_{\infty} \leq 1\}. \quad (40)$$

其中

$$\boldsymbol{\theta}_{c,k} = \begin{bmatrix} \frac{\theta_{o_1}^{\text{in}+}(k) + \theta_{o_1}^{\text{in}-}(k)}{2} \\ \vdots \\ \frac{\theta_{o_n}^{\text{in}+}(k) + \theta_{o_n}^{\text{in}-}(k)}{2} \end{bmatrix}, \quad (41)$$

$$\mathbf{T}_k = \text{diag} \left\{ \begin{array}{c} \frac{\theta_{o_1}^{\text{in}+}(k) - \theta_{o_1}^{\text{in}-}(k)}{2} \\ \vdots \\ \frac{\theta_{o_n}^{\text{in}+}(k) - \theta_{o_n}^{\text{in}-}(k)}{2} \end{array} \right\}. \quad (42)$$

1) 当 $q=j$ 时, 有

$$\begin{cases} \theta_{o_q}^{\text{in}+}(k) = \theta_{o_q}^+(k-1) + 2\gamma_q^{\text{max}}, \\ \theta_{o_q}^{\text{in}-}(k) = \theta_{o_q}^-(k-1) - 2\gamma_q^{\text{max}}. \end{cases} \quad (43)$$

2) 当 $q \neq j$ 且 $1 \leq q \leq n$ 时, 有

$$\begin{cases} \theta_{o_q}^{\text{in}+}(k) = \theta_{o_q}^+(k-1), \\ \theta_{o_q}^{\text{in}-}(k) = \theta_{o_q}^-(k-1). \end{cases} \quad (44)$$

证明 由式(8)可知, 对于在任何时刻发生故障, 参数向量的任一组成部分的变化都在一定的范围内, 即

$$\begin{bmatrix} |\Delta\theta_{f_{a_1}}(k)| \\ \vdots \\ |\Delta\theta_{f_{a_n}}(k)| \end{bmatrix} \leq \begin{bmatrix} \gamma_1^{\text{max}} \\ \vdots \\ \gamma_n^{\text{max}} \end{bmatrix}, \quad \forall k. \quad (45)$$

如果参数向量在 k 时刻第 j 个组成部分发生故障, 即

$$|\Delta\theta_{f_{a_j}}(k)| \leq \gamma_j^{\text{max}}, \quad (46)$$

则由

$$|\Delta\theta_{f_{a-1_j}}(k)| \leq \gamma_j^{\text{max}} \quad (47)$$

可得

$$\begin{aligned} |\Delta\theta_{f_{a_j}}(k) - \Delta\theta_{f_{a-1_j}}(k)| &\leq \\ |\Delta\theta_{f_{a_j}}(k)| + |\Delta\theta_{f_{a-1_j}}(k)| &\leq 2\gamma_j^{\text{max}}. \end{aligned} \quad (48)$$

由于

$$\theta_{f_{a_j}}(k) = \theta_{o_j} + \Delta\theta_{f_{a_j}}(k) =$$

$$\begin{aligned} \theta_{o_j} + \Delta\theta_{f_{a-1_j}}(k) + (\Delta\theta_{f_{a_j}}(k) - \Delta\theta_{f_{a-1_j}}(k)) = \\ \theta_{f_{a-1_j}}(k) + \Delta\theta_{f_{a_j}}(k) - \Delta\theta_{f_{a-1_j}}(k), \end{aligned} \quad (49)$$

利用式(48)可得

$$-2\gamma_j^{\max} \leq \Delta\theta_{f_{a_j}}(k) - \Delta\theta_{f_{a-1_j}}(k) \leq 2\gamma_j^{\max}. \quad (50)$$

又由于

$$\theta_{o_j}^-(k-1) \leq \theta_{f_{a-1_j}}(k) \leq \theta_{o_j}^+(k-1), \quad (51)$$

由式(49)~(51)可得, $\theta_{f_{a_j}}(k)$ 必定在如下的定向扩展里:

$$\begin{cases} \theta_{o_j}^{\text{in}+}(k) = \theta_{o_j}^+(k-1) + 2\gamma_j^{\max}, \\ \theta_{o_j}^{\text{in}-}(k) = \theta_{o_j}^-(k-1) - 2\gamma_j^{\max}. \end{cases}$$

由于参数向量的其他组成部分没有发生故障, 参数值没有发生变化, 即 $q \neq j$, 边界值无需扩展, 即

$$\begin{cases} \theta_{o_q}^{\text{in}+}(k) = \theta_{o_q}^+(k-1), \\ \theta_{o_q}^{\text{in}-}(k) = \theta_{o_q}^-(k-1). \end{cases} \quad \square$$

综上, 本文提出的基于正交超平行空间定向扩展的滤波故障诊断(orthometric hyperparallel spatial directional expansion filtering based fault diagnosis, OHSDEF-FD)算法步骤如下.

step 1: 令 $k = 1$, 初始化 $\mathcal{P}(\mathbf{T}_1, \boldsymbol{\theta}_{c,1})$ 和 $\mathcal{P}_o(\mathbf{T}_1, \boldsymbol{\theta}_{c,1})$, 给定时间长度 L , 参数变化最大值 γ^{\max} 和采样时间 N .

step 2: 获得测量带 $S(\mathbf{p}_k, c_k)$, 利用式(22)求出标量 ϵ_0^+ 和 ϵ_0^- , 如果 $\epsilon_0^+ < -1$ 或者 $\epsilon_0^- > 1$, 则检测到系统发生故障, 跳转到 step 4; 反之, 判定系统没有发生故障, 继续 step 3.

step 3: 由式(13)求出 $\mathcal{P}(\mathbf{T}_k, \boldsymbol{\theta}_{c,k})$, 再由式(23)~(27)求解 $\mathcal{P}_o(\mathbf{T}_k, \boldsymbol{\theta}_{c,k})$, 跳转到 step 6.

step 4: 获得测量带 $S(\mathbf{p}_k, c_k), \dots, S(\mathbf{p}_{k+L}, c_{k+L})$, 由式(31)和(32)获得 n 个正交超平行空间测试集 $\mathcal{P}_{o,d}^t(\mathbf{T}_{k-1}, \boldsymbol{\theta}_{c,k-1})$, 再利用式(13)进行 L 次计算得到 n 个超平行空间测试集 $\mathcal{P}_d^t(\mathbf{T}_{k+L}, \boldsymbol{\theta}_{c,k+L})$.

step 5: 根据 $\mathcal{P}_d^t(\mathbf{T}_{k+L}, \boldsymbol{\theta}_{c,k+L})$ 的状态由定理1隔离出具体的故障参数, 并由式(33)作出定向扩展得到初始化正交超平行空间 $\mathcal{P}_o^{\text{in}}(\mathbf{T}_k, \boldsymbol{\theta}_{c,k})$.

step 6: 令 $k = k + 1$, 返回到 step 2, 直至 $k = N$ 时, 算法结束, 输出故障诊断结果.

4 仿真分析

仿真1 对于下列线性动态系统模型:

$$y(k) = u(k-1) + 0.8u(k-2) + e(k). \quad (52)$$

其中: $\boldsymbol{\theta} = [1, 0.8]^T$ 为系统真值, $e(k)$ 为未知但有界噪声且 $|e(t)| \leq 0.1$. 给定时间长度 $L = 5$, $\gamma_1^{\max} = \gamma_2^{\max} = 1$. 设定在 $k = 501$ 时刻发生故障1为 $\boldsymbol{\theta}_{f_1}(k) = [1.5, 0.8]^T$; 在 $k = 1001$ 时刻发生故障2为 $\boldsymbol{\theta}_{f_2}(k) = [1.5, 1.2]^T$. 使用本文提出的基于正交超平行空间定向扩展的算法(OHSDEF-FD)进行故障诊断, 同时与文献[25]中的基于集员辨识的故障诊断算法(fault diagnosis based on set membership identification using output-error models, SMIOE-FD)进行对比, 结果如图2~图4所示.







图2 OHSDEF-FD算法与SMIOE-FD算法对比

在图2中: 玫红色表示SMIOE-FD算法中椭球包裹可行集的区域, 蓝色表示OHSDEF-FD算法中超平行空间包裹可行集的区域, 红色星点表示系统真值.

由图2可以看出, 在不同的采样点, OHSDEF-FD算法都能紧紧包裹住真值, 且同SMIOE-FD算法对比, OHSDEF-FD算法包裹的参数可行集面积更小, 意味着本文所提算法的保守性更小, 空间冗余度更低.

由图3和图4可以看出: 在 $k = 501$ 时, θ_2 定向扩展但 θ_1 不定向扩展, 说明检测出故障发生并隔离出故障参数 θ_2 ; 同理, OHSDEF-FD算法检测出 $k = 1001$ 时, 系统发生故障并隔离出故障参数 θ_1 . 与SMIOE-FD算法相比, OHSDEF-FD算法参数识别的收敛速度更快, 上下界更密集地包裹着真值, 且OHSDEF-FD估计出的真值更加接近系统真值, 进一步体现出本文所提算法的保守性更小, 空间冗余度更低.

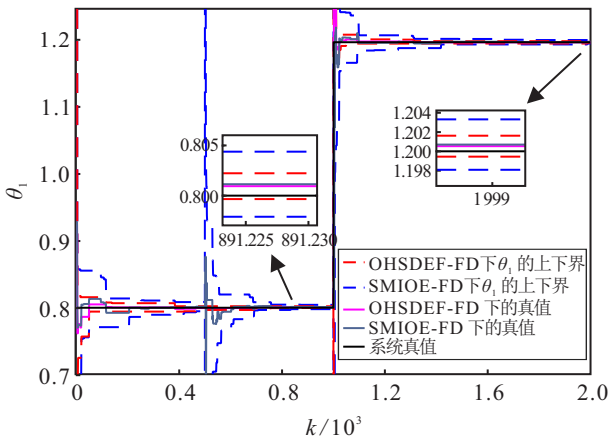


图3 θ_1 的上下界变化

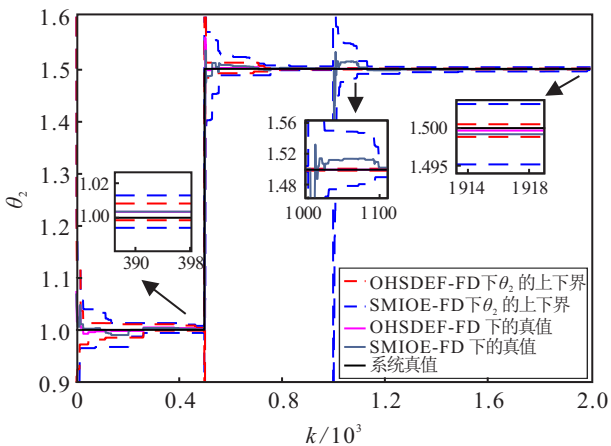


图4 θ_2 的上下界变化

仿真2 桨距子系统在风力发电系统中是控制桨叶和桨距角的重要组成部分, 为了进一步检验本文提出的故障诊断算法的有效性和可行性, 本文利用OHSDEF-FD算法对风力发电机的桨距子系统进行

仿真. 桨距子系统如图5所示

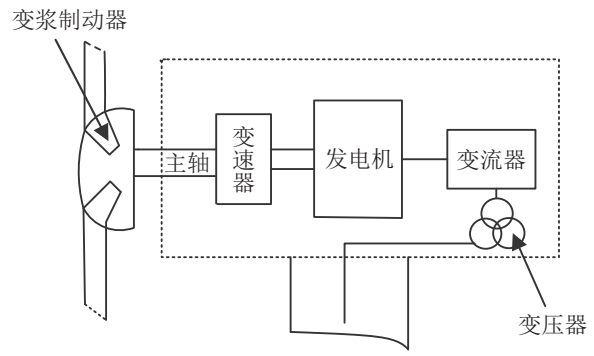


图5 桨距子系统

桨距子系统的数学模型^[29-30]可表示为

$$\begin{bmatrix} \dot{\beta} \\ \dot{\beta}_a \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ -\omega_n^2 & -2\zeta\omega_n \end{bmatrix} \begin{bmatrix} \beta \\ \beta_a \end{bmatrix} + \begin{bmatrix} 0 \\ \omega_n^2 \end{bmatrix} \beta_r. \quad (53)$$

其中: β 和 β_a 分别为桨距角和角速度大小, β_r 为桨距的参考值, ζ 和 ω_n 分别为阻尼系数和系统的固有频率. 由式(53)可得

$$\begin{cases} \dot{\beta} = \beta_a, \\ \dot{\beta}_a = -\omega_n^2\beta - 2\zeta\omega_n\beta_a + \omega_n^2\beta_r. \end{cases}$$

可见 β_a 是 β 的一阶导数, 消去 β_a 得到

$$\ddot{\beta} = -\omega_n^2\beta - 2\zeta\omega_n\dot{\beta} + \omega_n^2\beta_r.$$

由拉式变换可得

$$s^2\beta = -\omega_n^2\beta - 2\zeta\omega_n s\beta + \omega_n^2\beta_r.$$

整理后有

$$(s^2 + 2\zeta\omega_n s + \omega_n^2)\beta = \omega_n^2\beta_r,$$

即

$$\frac{y}{u} = \frac{\omega_n^2}{s^2 + 2\zeta\omega_n s + \omega_n^2}. \quad (54)$$

其中: $y = \beta, u = \beta_r$. 根据文献[29], 取 $\zeta = 0.6, \omega_n = 11.11 \text{ rad/s}$, 给定采样时间 $T_s = 0.01 \text{ s}$, 则可将系统(54)离散化为

$$A(z)y(k) = B(z)u(k) + e(k). \quad (55)$$

其中

$$\begin{aligned} A(z) &= 1 - 1.864z^{-1} + 0.8752z^{-2}, \\ B(z) &= 0.0059z^{-1} + 0.0056z^{-2}. \end{aligned}$$

可以看出, 系统(55)的参数个数 $n = 4$, 参数真值为 $\theta = [-1.864, 0.8752, 0.0059, 0.0056]^T$. 设置输入信号 $|u(k)| \leq 20$, 噪声幅值 $|e(k)| \leq 0.2$, 给定时间长度 $L = 5, \gamma_1^{\max} = \gamma_2^{\max} = \gamma_3^{\max} = \gamma_4^{\max} = 2$. 根据文献

[29]对系统加入以下表1所示的3种故障状态.

表1 系统的运行状态和参数

状态	故障原因	θ_1	θ_2	θ_3	θ_4
无故障	无故障	-1.864	0.8752	0.0059	0.0056
故障1	液压泄露	-1.520	0.8752	0.0059	0.0056
故障2	泵磨损	-1.520	1.020	0.4038	0.0056
故障3	空气含量增加	-1.520	1.020	0.2038	0.3028

预定的时间范围内,在 $k = 501, k = 1001$ 和 $k = 1501$ 时刻分别对系统加入故障1、故障2和故障3,在参数变化过程中,利用本文提到的 OHSDEF-FD 算法计算每个参数的上下界,同时与文献[25]的 SMIOE-FD 算法进行对比,结果如图6~图9所示.

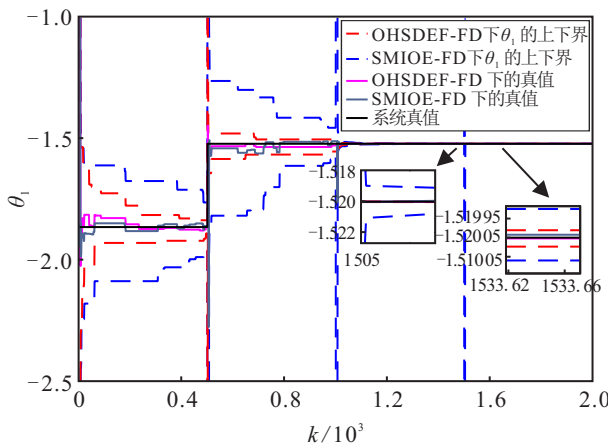


图6 θ_1 的上下界变化




图7 θ_2 的上下界变化

由图6~图9可以看出:在 $k = 501$ 时刻, θ_1 定向扩展但 $\theta_2, \theta_3, \theta_4$ 不定向扩展,说明检测出故障发生并隔离出故障参数 θ_1 ; 同理,在 $k = 1001$ 时刻,检测出故障发生并隔离出故障参数 θ_2, θ_3 ; 在 $k = 1501$ 时刻,检测出故障发生并隔离出故障参数 θ_3, θ_4 . 说明此算法不仅可以快速检测出故障,而且可以快速地隔离出故障参数. 同时由图6~图9可以看出,与 SMIOE-FD 算法对比, OHSDEF-FD 算法都只定向扩展故障参数而不影响其他参数的滤波估计,并且无论系统故障

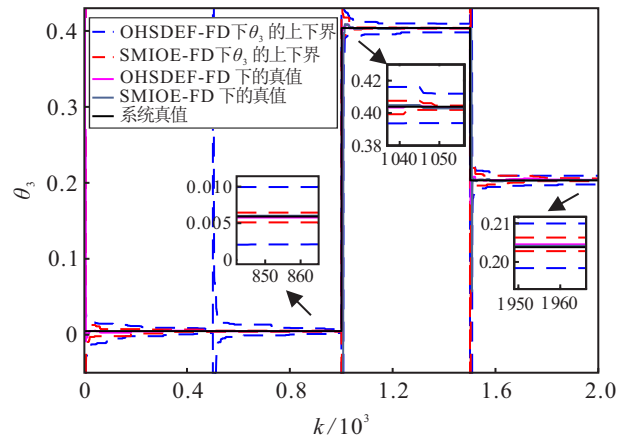


图8 θ_3 的上下界变化




图9 θ_4 的上下界变化

与否, OHSDEF-FD 算法的滤波估计曲线收敛速度更快,给出的参数上下界区间范围更小,说明本文所提 OHSDEF-FD 算法的保守性更低,空间冗余度更低.

5 结论

针对含未知但有界噪声干扰的线性递归系统故障诊断问题,本文提出了基于正交超平行空间定向扩展的滤波故障诊断方法. 首先利用超平行空间包裹参数可行集,完成无故障状态下基于滤波的参数辨识,同时设定正交超平行空间,保证了参数边界值的单调收敛;利用当前超平行空间与带空间的交集是否为空,检测系统是否发生故障;在检测故障发生后,利用超平行空间测试集的状态隔离故障参数,再设计定向扩展策略得到包裹故障参数的初始化正交超平行空间,进而完成故障识别. 本文所提方法可以实现工业系统环境中不确定干扰下的状态估计与诊断,进而可推广至解决移动机器人定位^[31]、化工过程故障诊断^[32]等实际工程问题.

参考文献(References)

[1] 姜斌, 吴云凯, 陆宁云, 等. 高速列车牵引系统故障诊断与预测技术综述[J]. 控制与决策, 2018, 33(5):

- 841-855.
(Jiang B, Wu Y K, Lu N Y, et al. Review of fault diagnosis and prognosis techniques for high-speed railway traction system[J]. *Control and Decision*, 2018, 33(5): 841-855.)
- [2] 王金鑫, 王忠巍, 马修真, 等. 柴油机燃油系统多故障的解耦与诊断技术[J]. *控制与决策*, 2019, 34(10): 2249-2255.
(Wang J X, Wang Z W, Ma X Z, et al. Decoupling and diagnosis of multi-fault of diesel engine fuel system[J]. *Control and Decision*, 2019, 34(10): 2249-2255.)
- [3] Sharan B D, Jain T. Spectral analysis-based fault diagnosis algorithm for 3-phase passive rectifiers in renewable energy systems[J]. *IET Power Electronics*, 2020, 13(16): 3818-3829.
- [4] 杨光红, 张志慧. 基于区间观测器的动态系统故障诊断技术综述[J]. *控制与决策*, 2018, 33(5): 769-781.
(Yang G H, Zhang Z H. Review of interval observer based fault diagnosis techniques for dynamic systems[J]. *Control and Decision*, 2018, 33(5): 769-781.)
- [5] 曲建岭, 余路, 袁涛, 等. 基于卷积神经网络的层级化智能故障诊断算法[J]. *控制与决策*, 2019, 34(12): 2619-2626.
(Qu J L, Yu L, Yuan T, et al. A hierarchical intelligent fault diagnosis algorithm based on convolutional neural network[J]. *Control and Decision*, 2019, 34(12): 2619-2626.)
- [6] 彭开香, 马亮, 张凯. 复杂工业过程质量相关的故障检测与诊断技术综述[J]. *自动化学报*, 2017, 43(3): 349-365.
(Peng K X, Ma L, Zhang K. Review of quality-related fault detection and diagnosis techniques for complex industrial processes[J]. *Acta Automatica Sinica*, 2017, 43(3): 349-365.)
- [7] Jiang G Q, He H B, Xie P, et al. Stacked multilevel-denoising autoencoders: A new representation learning approach for wind turbine gearbox fault diagnosis[J]. *IEEE Transactions on Instrumentation and Measurement*, 2017, 66(9): 2391-2402.
- [8] Rayyam M, Zazi M. A novel metaheuristic model-based approach for accurate online broken bar fault diagnosis in induction motor using unscented Kalman filter and ant lion optimizer[J]. *Transactions of the Institute of Measurement and Control*, 2019, 42(8):1537-1546.
- [9] 陆宁云, 孟宪锋, 姜斌, 等. 基于多信号模型和盲源分离的复合故障诊断方法[J]. *控制与决策*, 2016, 31(11): 1945-1952.
(Lu N Y, Meng X F, Jiang B, et al. Compound fault diagnosis method based on multi-signal model and blind source separation[J]. *Control and Decision*, 2016, 31(11): 1945-1952.)
- [10] Feng J, Yao Y, Lu S X, et al. Domain knowledge-based deep-broad learning framework for fault diagnosis[J]. *IEEE Transactions on Industrial Electronics*, 2021, 68(4): 3454-3464.
- [11] 郭金玉, 刘玉超, 李元. 基于局部熵双子空间的多模态过程故障检测[J]. *控制理论与应用*, 2020, 37(9): 2020-2028.
(Guo J Y, Liu Y C, Li Y. Fault detection of multimodal processes based on local entropy double subspace[J]. *Control Theory & Applications*, 2020, 37(9): 2020-2028.)
- [12] 周波, 钱堃, 马旭东, 等. 基于集员估计的室内移动机器人多传感器融合定位[J]. *控制理论与应用*, 2017, 34(4): 541-550.
(Zhou B, Qian K, Ma X D, et al. Multi-sensor fusion for mobile robot indoor localization based on a set-membership estimator[J]. *Control Theory & Applications*, 2017, 34(4): 541-550.)
- [13] Kamal E, Adouane L. Hierarchical energy optimization strategy and its integrated reliable battery fault management for hybrid hydraulic-electric vehicle[J]. *IEEE Transactions on Vehicular Technology*, 2018, 67(5): 3740-3754.
- [14] Meslem N, Hably A. Robust set-membership state estimator against outliers in data[J]. *IET Control Theory & Applications*, 2020, 14(13): 1752-1761.
- [15] Zhou M, Cao Z C, Zhou M C, et al. Zonotopic fault estimation for discrete-time LPV systems with bounded parametric uncertainty[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2020, 21(2): 690-700.
- [16] Bolting J, Fergani S. The iterated extended set membership filter applied to relative localization between autonomous vehicles based on GNSS and UWB ranging[J]. *Asian Journal of Control*, 2019, 21(4): 1556-1565.
- [17] Li X R, Han F, Hou N, et al. Set-membership filtering for piecewise linear systems with censored measurements under Round-Robin protocol[J]. *International Journal of Systems Science*, 2020, 51(9): 1578-1588.
- [18] Wang Z G, Shen X J, Zhu Y M. Ellipsoidal fusion estimation for multisensor dynamic systems with bounded noises[J]. *IEEE Transactions on Automatic Control*, 2019, 64(11): 4725-4732.
- [19] Wang J H. Zonotope parameter identification for piecewise affine systems[J]. *Journal of Systems Engineering and Electronics*, 2020, 31(5): 1077-1084.
- [20] Zhang Z H, Wang Z H, Tang W T, et al. Zonotopic reachable set estimation for linear discrete-time systems with time delay[J]. *International Journal of Robust and*

- Nonlinear Control, 2020, 30(14): 5542-5558.
- [21] 沈艳霞, 尹天骄. 一种基于凸多面体的集员滤波故障诊断方法[J]. 控制与决策, 2018, 33(1): 150-156.
(Shen Y X, Yin T J. A fault diagnosis method of set membership filter based on convex ploytope[J]. Control and Decision, 2018, 33(1): 150-156.)
- [22] Wang Z Y, Xu G X, Liu Z X, et al. Orthotopic-filtering-based fault diagnosis algorithms for nonlinear systems with slowly varying faults[J]. Journal of the Franklin Institute, 2020, 357(9): 5610-5639.
- [23] 王子赞, 徐桂香, 刘子幸, 等. 基于正多胞体线性规划的滤波故障诊断方法[J]. 控制与决策, 2020, 35(4): 807-815.
(Wang Z Y, Xu G X, Liu Z X, et al. Orthotopic linear programming filtering based fault diagnosis method[J]. Control and Decision, 2020, 35(4): 807-815.)
- [24] Zhou B, Qian K, Ma X D, et al. Ellipsoidal bounding set-membership identification approach for robust fault diagnosis with application to mobile robots[J]. Journal of Systems Engineering and Electronics, 2017, 28(5): 986-995.
- [25] Reppa V, Tzes A. Fault diagnosis based on set membership identification using output-error models[J]. International Journal of Adaptive Control and Signal Processing, 2016, 30(2): 224-255.
- [26] Sharma U, Thangavel S, Mukkula A R G, et al. Effective recursive parallelotopic bounding for robust output-feedback control[C]. The 18th IFAC Symposium on System Identification. Sweden, 2018: 1032-1035.
- [27] Liu Z X, Wang Z Y, Wang Y, et al. Directional expansion-based fault diagnosis algorithm using orthotopic and ellipsoidal filtering[J]. IET Control Theory & Applications, 2020, 14(18): 2836-2846.
- [28] Valero C E, Paulen R. Effective recursive set-membership state estimation for robust linear MPC[J]. IFAC-PapersOnLine, 2019, 52(1): 486-491.
- [29] Casau P, Rosa P, Tabatabaeipour S M, et al. A set-valued approach to FDI and FTC of wind turbines[J]. IEEE Transactions on Control Systems Technology, 2015, 23(1): 245-263.
- [30] Yang Z, Wang S, Ma C, et al. Development of fault diagnosis system for wind power planetary transmission based on labview[J]. The Journal of Engineering, 2019, 2019(23): 9170-9172.
- [31] 张文安, 陈国庆, 杨旭升. UHF-RFID环境下的移动机器人定位方法[J]. 控制与决策, 2018, 33(10): 1807-1812.
(Zhang W A, Chen G Q, Yang X S. Mobile robot localization method in UHF-RFID[J]. Control and Decision, 2018, 33(10): 1807-1812.)
- [32] Ziaei-Halimejani H, Zarghami R, Mansouri S S, et al. Data-driven fault diagnosis of chemical processes based on recurrence plots[J]. Industrial & Engineering Chemistry Research, 2021, 60(7): 3038-3055.

作者简介

王子赞(1989—), 男, 副教授, 博士, 从事复杂系统故障诊断和滤波理论等研究, E-mail: wangzy0601@163.com;

程林(1998—), 女, 硕士生, 从事滤波算法分析和故障诊断方法的研究, E-mail: 1548962998@qq.com;

王艳(1978—), 女, 教授, 博士生导师, 从事生产过程建模与优化控制、先进滤波理论等研究, E-mail: yanwang@jiangnan.edu.cn;

纪志成(1959—), 男, 教授, 博士生导师, 从事工业过程建模和智能算法、状态估计领域等研究, E-mail: zcji@jiangnan.edu.cn.

(责任编辑: 闫妍)