

DOI:10.11918/202108109

# 一种基于双重改进粒子滤波器的故障隔离方法

莫浩彬, 李艳军

(南京航空航天大学 民航学院, 南京 211106)

**摘要:**为了解决在基于解析冗余关系的故障诊断应用中难以实现故障隔离的问题,提出了一种基于双重改进粒子滤波器的故障隔离方法。该方法利用状态和参数估计粒子滤波器组成的联合估计模型,对系统状态和潜在故障参数值进行联合估计,通过对比潜在故障参数估计值与其标称值实现故障隔离。在联合估计模型中,一方面,在传统的随机扰动法的基础上,利用最大似然估计法获得参数时间更新梯度,使用一种改进随机扰动法实现参数时间更新;另一方面,在采样过程中考虑当前量测值,并引入粒子群和模拟退火优化思想,使用一种采样粒子质量改进方法实现粒子采样,以提升其估计性能。仿真结果表明:在假设的两类参数型故障下,基于双重粒子滤波器的联合估计模型在鲁棒性、计算速度和估计精度上均优于基于扩展状态空间的粒子滤波器联合估计模型,在基于双重粒子滤波器的联合估计模型上,使用所提出的改进方法能显著提升其估计性能。所提出的方法基本满足参数型故障隔离对计算效率和估计精度的要求,可作为基于解析冗余关系故障诊断中的故障隔离方法。

**关键词:** 粒子滤波器;故障隔离;联合估计方法;粒子群优化;模拟退火优化;最大似然估计

**中图分类号:** TN713

**文献标志码:** A

**文章编号:** 0367-6234(2023)03-0038-11

## Fault isolation method based on a dual improved particle filter

MO Haobin, LI Yanjun

(College of Civil Aviation, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China)

**Abstract:** In view of the problem that it is difficult to realize fault isolation when using the analytical redundancy relations-based fault diagnosis (ARRBFD) method, this paper presents a dual improved particle filter method for fault isolation. The method employs the joint estimation model composed of state and parameter estimation particle filters to jointly estimate the values of system state and potential fault parameter, and it achieves fault isolation by comparing the estimated value of the potential fault parameter with its nominal value. In the joint estimation model, on the basis of the traditional random perturbation method, an improved random perturbation method was developed to realize the parameter time update, which uses the maximum likelihood estimation method to obtain the parameter time update gradient. Then, a sampling method was proposed to improve the sampling particle quality, which takes into account the current measured values in the sampling process and introduces the idea of particle swarm optimization and simulated annealing optimization. Simulation results show that under the two types of parametric faults assumed in this paper, the joint estimation model based on dual particle filter outperformed the joint estimation model based on extended state space in terms of robustness, calculation speed, and estimation accuracy. The proposed method significantly improved the estimation performance in the joint estimation model based on the dual particle filter. In conclusion, the proposed method meets the requirements of computational efficiency and estimation accuracy for parametric fault isolation, and it can realize the fault isolation when applying the ARBFD method.

**Keywords:** particle filter; fault isolation; joint estimation method; particle swarm optimization; simulated annealing optimization; maximum likelihood estimation

故障诊断指故障检测和故障隔离的过程。其中,故障检测的目的是检查是否发生故障和确定故障发生时间,故障隔离的目的是寻找故障发生位置<sup>[1]</sup>。先进的故障诊断技术有利于提高多能域工

程系统的安全性、可靠性以及运行效率。其中,基于解析冗余关系的故障诊断(analytical redundancy relations-based fault diagnosis, ARBFD)方法,因其具有适用范围广、解释性强、可实现在线监测等优

收稿日期: 2021-08-26; 录用日期: 2021-12-20; 网络首发日期: 2022-11-07

网络首发地址: <https://kns.cnki.net/kcms/detail/23.1235.T.20221104.1922.004.html>

基金项目: 航空科学基金(2020033052001)

作者简介: 莫浩彬(1996—),男,硕士研究生; 李艳军(1969—),男,教授,博士生导师

通信作者: 莫浩彬, mohaobin@nuaa.edu.cn

势<sup>[2]</sup>,正被广泛运用到各个工程领域。但是在实际非线性系统故障诊断的应用中,单纯使用 ARBFD 方法往往只能实现故障检测,而无法完成故障隔离。根据 ARBFD 故障诊断结果可以推断出潜在故障参数集(potential fault parameters set, PFPS)。此时,如果可以得到 PFPS 内各参数估计值,再将其与标称值进行对比,即可实现故障隔离。考虑到经 ARBFD 得到的 PFPS 中各参数,不仅其种类和真实值未知,且其是否随时间变化也未知<sup>[3]</sup>。本文假设各参数为时变参数,将故障隔离问题转换为系统状态与时变参数联合估计问题。

对于联合估计问题,目前主要有两种方法:一是基于扩展状态空间的方法<sup>[4]</sup>,将待估计参数作为状态的扩展项,利用滤波器同时对系统状态和参数进行估计。该方法结构简单,易于实现,但扩展后的状态空间维度较高,容易导致维数灾难问题<sup>[5]</sup>。且估计值易受量测噪音等系统不确定性的影响而发散,导致精度降低甚至估计失效<sup>[6]</sup>。二是基于双重滤波器的方法<sup>[7]</sup>,使用两个滤波器分别对系统状态和参数进行估计。该方法暂时分离了状态和代估参数变量,在文献[8]中,使用了 EF 算法复杂度计算方法<sup>[9]</sup>,证明了使用相同的粒子数量时,基于双重滤波器的方法在计算速度和估计精度上均优于基于扩展状态空间的方法。

上述两种联合估计方法的有效性及其估计精度都依赖所选取的滤波器。对于线性系统或者简单的非线性系统,卡尔曼滤波器、扩展卡尔曼滤波器和无迹卡尔曼滤波器等都具有出色的表现<sup>[10]</sup>,但在复杂的非线性系统中往往表现不佳甚至无法使用。随着滤波技术的发展,粒子滤波方法在非线性系统中具有优越性。文献[11]早在 1997 年就开始利用粒子滤波器解决联合估计问题。但粒子滤波器普遍存在粒子退化和样本匮乏现象<sup>[12]</sup>,导致粒子集无法正确表示真实后验概率分布,需要采取一定措施遏制粒子退化并增加粒子多样性。常用的一种方法是将各种智能优化思想如遗传算法、粒子群算法和生物地理学优化算法等引入到粒子滤波算法的采样过程中<sup>[13-15]</sup>,改进采样粒子质量。

此外,在参数滤波过程中,由于代估参数的先验概率密度分布未知,需要人工定义其参数时间更新方法。在时变参数假设下,随机扰动法<sup>[15]</sup>是一种常用的参数时间更新方法,为了提高粒子有效性,需要大量增加采样粒子数量或扩大随机项,进而导致所需计算资源陡升;另一方面抗干扰能力较差,易受噪声等系统不确定性因素的影响。为了解决上述问题,文献[8]在随机扰动法的基础上引入预测误差

思想,对参数采样过程进行改进。与单纯使用随机扰动法相比,该方法得到的参数估计精度更高且收敛速度更快,证明了该方法的有效性,但仅适合对预定义的固定参数集进行估计。由于 PFPS 是由 ARBFD 结果推断得出,并不是固定的,无法事先定义,所以文献[8]方法难以扩展到潜在故障参数集。文献[15]提出了一种基于最大似然估计的参数时间更新方法,该方法结构简单且易于扩展,但仅适用于时不变参数的离线估计中。

本文提出一种基于双重改进粒子滤波器的联合估计方法,在基于解析冗余关系的故障诊断应用中完成故障隔离。其中,为了提升联合估计模型的性能,本文从两个方面对其所采用的粒子滤波算法进行改进:1)将文献[8]和文献[15]方法相结合,在传统的基于随机扰动法的参数时间更新方法上,引入最大似然估计法,提出一种改进随机扰动法实现参数时间更新;2)在标准粒子滤波算法的基础上,引入粒子群和模拟退火优化思想,提出一种采样粒子质量改进方法。

## 1 潜在故障参数集的获取

在 ARBFD 中,当系统在无故障状态下运行时,各个解析冗余关系(analytical redundancy relations, ARR),应均为零值或近似零值;当系统在有故障状态下运行时,若表现为某系统参数偏离正常值,则含该参数的 ARR 会偏离零值。根据这个特性,可以设计故障特征矩阵<sup>[2]</sup>,其可以根据系统实际运行过程中 ARR 的响应来推导出 PFPS。

如表 1 所示,3 个参数都具备可检测性,标记为  $D_b = 1$ 。若 ARR1 和 ARR2 同时偏离零值,则 PFPS 内只有一个潜在故障参数为参数 3,具备可隔离性,标记为  $I_b = 0$ 。但若只有 ARR1 偏离零值,则 PFPS 内含有两个潜在故障参数为参数 1 和参数 2,不具备可隔离性,标记为  $I_b = 0$ 。

表 1 故障特征矩阵示例

Tab.1 Example of fault characteristic matrix

故障参数	ARR1	ARR2	ARR3	$D_b$	$I_b$
参数 1	1	0	0	1	0
参数 2	1	0	0	1	0
参数 3	1	1	0	1	1

## 2 基于双重粒子滤波器状态及故障参数联合估计方法

### 2.1 问题概述

对于非线性随机系统而言,其状态变量  $x_i$  和量测值  $y_i$  随时间演变过程可以描述为一个离散随机

时间模型:

$$x_t = f(x_{t-1}, \theta_t) + \mu_t \quad (1)$$

$$y_t = g(x_t, \theta_t) + v_t \quad (2)$$

其中:  $t \in \mathbf{N}$  为系统的离散随机序列;  $x_t \in \mathbf{R}^{n_x}$  和  $y_t \in \mathbf{R}^{n_y}$  为时刻  $t$  系统状态变量和量测值;  $\theta_t \in \mathbf{R}^{n_\theta}$  为时刻  $t$  系统参数;  $f(\cdot): \mathbf{R}^{n_x} \times \mathbf{R}^{n_\theta} \rightarrow \mathbf{R}^{n_x}$  为系统过程转换函数;  $g(\cdot): \mathbf{R}^{n_x} \times \mathbf{R}^{n_\theta} \rightarrow \mathbf{R}^{n_y}$  为系统量测函数;  $\mu_t \in \mathbf{R}^{n_\mu}$  和  $v_t \in \mathbf{R}^{n_\nu}$  为时刻  $t$  系统过程噪声和量测噪声。

联合估计问题需要根据系统由时刻 1 到  $t$  的所有量测值  $y_{1:t}$  估计联合后验概率密度函数  $p(x_t, \theta_t | y_{1:t})$ 。然而对于大多数问题, 很难得到其解析表达式。可将联合后验概率密度函数分解为系统状态的边缘概率密度函数  $p(x_t | \theta_t, y_{1:t})$  和系统参数的边缘概率密度函数  $p(\theta_t | x_{t-1}, y_{1:t})$ , 两者通过依次更新, 实现时刻  $t$  系统状态与故障参数联合估计。估计系统状态值和潜在故障参数值在当前时刻  $t$  的值  $\hat{x}_t, \hat{\theta}_{p,t}$ , 即计算时刻  $t$  系统状态值与潜在故障参数值的数学期望:

$$E(\hat{\theta}_{p,t}) = E(\hat{\theta}_t) = \int \hat{\theta}_t p(\hat{\theta}_t | x_{t-1}, y_{1:t}) d\hat{\theta}_t \quad (3)$$

$$E(\hat{x}_t) = \int \hat{x}_t p(\hat{x}_t | \hat{\theta}_t, y_{1:t}) d\hat{x}_t \quad (4)$$

式中:  $\theta_{p,t}$  和  $\theta_{-p,t}$  为时刻  $t$  的潜在故障参数集和非潜在故障参数集的值, 满足  $\theta_t = \{\theta_{p,t} \cup \theta_{-p,t}\}$ 。

## 2.2 粒子滤波器

基于贝叶斯估计, 可以得到以下递归形式的时刻  $t$  系统状态与故障参数值的后验边缘概率密度:

$$p(\theta_t | y_{1:t}, x_{t-1}) = p(\theta_{t-1} | y_{1:t-1}, x_{t-2}) \times \frac{p(y_t | x_{t-1}, \theta_t) p(\theta_t | \theta_{t-1}, x_{t-1})}{\int p(y_t | x_{t-1}, \theta_t) p(\theta_t | y_{1:t-1}, x_{t-1}) d\theta_t} \quad (5)$$

$$p(x_t | y_{1:t}, \theta_t) = p(x_{t-1} | y_{1:t-1}, \theta_{t-1}) \times \frac{p(y_t | x_t, \theta_t) p(x_t | x_{t-1}, \theta_t)}{\int p(y_t | x_t, \theta_t) p(x_t | y_{1:t-1}, \theta_t) dx_t} \quad (6)$$

本文使用粒子滤波算法对式(5)、(6)进行近似计算, 其通过在每一次迭代中产生一组具有权重的粒子对非线性系统进行递归估计, 式(5)、(6)经粒子滤波算法近似计算后可得式(7)、(8), 代入式(3)、(4)即可计算  $t$  时刻系统状态值与潜在故障参数值的数学期望。

$$\hat{p}(\theta_{p,t} | y_{1:t}, x_{t-1}) d\theta_{p,t} = \sum_{j=1}^N \omega_{\theta_t(j)} \delta(\theta_t - \theta_t^{(j)}) d\theta_t \quad (7)$$

$$\hat{p}(x_t | y_{1:t}, \theta_t) dx_t = \sum_{i=1}^N \omega_{x_t(i)} \delta(x_t - x_t^{(i)}) dx_t \quad (8)$$

式中:  $\hat{p}(\theta_{p,t} | y_{1:t}, x_{t-1})$  和  $\hat{p}(x_t | y_{1:t}, \theta_{t-1})$  表示  $N$  个

粒子近似得到的时刻  $t$  系统参数和状态的条件概率分布, 每一个状态粒子  $x_t^{(i)}$  的权重为  $\omega_{x_t(i)}$ , 每一个参数粒子  $\theta_t^{(j)}$  的权重为  $\omega_{\theta_t(j)}$ ,  $\delta(\cdot)$  表示狄拉克函数。

标准的粒子滤波器由时间更新和量测更新构成一个迭代周期, 使用粒子滤波器对状态和参数进行滤波估计的过程中, 两者仅在时间更新处有所区别。以状态估计为例, 其算法归纳如下:

1) 初始化, 由先验概率  $p(x_1)$  产生粒子群  $\{x_1^{(i)}\}_{i=1}^N$ , 所有粒子初始权值为  $1/N$ 。

2) 时间更新(采样),  $\tilde{x}_t^{(i)} \sim q(x_t | \tilde{x}_{t-1}^{(i)}, y_{1:t}, \hat{\theta}_t)$ 。

3) 量测更新, 包括权值更新、重采样以及估计值输出。权值更新  $\omega_t^{(i)} = \exp[-0.5(y_t - y_{\text{pred}}^{(i)}) / R_t]$ ,  $i = 1, 2, \dots, N$ ; 重采样, 将优化后的权值样本  $\{\tilde{x}_t^{(i)}, \tilde{\omega}_t^{(i)}\}_{i=1}^N$  映射成等权样本  $\{\tilde{x}_t^{(i)}, 1/N\}_{i=1}^N$ ; 输出估计值  $\hat{x}_t = \sum_{i=1}^N \tilde{x}_t^{(i)} / N$ 。

$y_t$  为量测值;  $y_{\text{pred}}$  为量测预测值, 由  $\tilde{x}_t$  代入式(2)计算得到对于参数时间更新, 其先验概率密度分布未知, 需要人工定义其更新方法才能实现参数时间更新。如采用文献[13]的随机扰动法进行采样, 则有

$$\tilde{\theta}_{p,t} = \hat{\theta}_{p,t} + \sqrt{Q} \cdot n \quad (9)$$

式中:  $Q$  为参数随机扰动方差;  $n \sim U(0, 1)$ 。

## 2.3 基于双重粒子滤波器的联合估计方案

假设在某一时刻 ARBFD 检测到系统故障, 令此时系统状态值和参数值为粒子滤波算法的初始值  $\hat{x}_1, \hat{\theta}_1(\hat{x}_{t-1}, \hat{\theta}_{t-1})$ 。在接下来的每一个时刻  $t$ , 由式(4)可知, 计算时刻  $t$  的状态  $\hat{x}_t$  依赖于时刻  $t$  的系统参数值  $\hat{\theta}_t$ 。所以, 本文提出的基于双重粒子滤波器的联合估计方案, 如图 1 所示, 首先调用参数估计粒子滤波器, 利用人工定义的方法得到参数时间更新值  $\tilde{\theta}_{p,t}$ , 再通过量测更新得到的参数最优估计值  $\hat{\theta}_{p,t}$ , 并对系统参数进行更新得到  $\hat{\theta}_t$ 。然后调用状态估计粒子滤波器, 利用  $\hat{\theta}_t$  得到系统状态时间更新值  $\tilde{x}_t$ , 再通过量测更新得到状态最优估计值  $\hat{x}_t$ 。

## 2.4 改进的参数时间更新方法

随机扰动法是一种常用的参数时间更新方法, 在每次迭代中, 通过定义一个随机项  $|\sigma|$ , 如式(9)中的  $\sqrt{Q} \cdot n$  来实现参数时间更新。当参数初始值与参数目标值差距  $D_\theta$  与  $|\sigma|$  接近时, RD 所生成的参数粒子能有效地逼近其真实后验边缘概率密度;

但当  $D_\theta$  远大于  $|\sigma|$ , 所生成的参数粒子有效性较低, 无法逼近其真实后验边缘概率密度, 进而导致参数估计算法无法收敛于目标值。

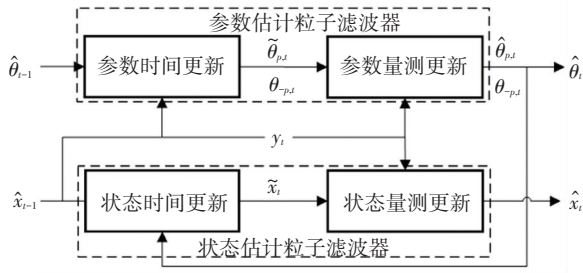


图1 基于双重粒子滤波器的联合估计方案

Fig.1 Joint estimation method based on dual particle filter

为了解决随机扰动法采样得到的粒子有效性低的问题, 本文在其基础上引入最大似然估计法对  $\theta_{p,t}$  进行初步时间更新; 同时考虑到参数具有时变特性, 对文献[16]传统的基于粒子滤波的最大似然估计法进行改进, 得到一种改进随机扰动法(modified random perturbation method, MRD)作为参数时间更新方法。该方法仅利用两个相邻的量测值  $y_{t-1:t}$ , 通过最大似然估计法推导得到参数时间更新梯度表达式, 然后利用粒子滤波方法对梯度表达式进行近似计算, 最后在所得梯度值为均值, 方差  $\sigma^2$  的正态分布中采样实现时刻  $t$  参数  $\theta_{p,t}$  时间更新。

算法归纳如下, 其中  $\lambda$ 、 $c$ 、 $\alpha$  和  $\beta$  的参数调整方法可从文献[18]中得到。

1) 初始化, 已知时刻  $t-1$  带权值的粒子为  $\{x_{t-1}^{(i)}, \omega_{t-1}^{(i)}, i=1, 2, \dots, N$ , 若  $t=1$ , 则带权值的粒子为  $\{x_1, 1/N\}, i=1, 2, \dots, N$ ; 设置初始参数更新步长  $\lambda$ 、初始参数扰动系数  $c$ 、步长衰减系数  $\alpha$  为 0.602、参数扰动衰减系数  $\beta$  为 0.101 和正态分布方差  $\sigma^2$ ; 定义  $\theta_{p(k),t}$  为  $\theta_{p,t}$  内某参数,  $k=1, 2, \dots, N_k$ , 其中  $N_k$  为  $\theta_{p,t}$  内参数数量。

2) 在时刻  $t$  分别对每个  $\theta_{p(k),t}$  进行时间更新。更新时刻  $t$  参数更新步长  $\lambda_t = \lambda / (t + 100)^\alpha$  和参数扰动系数  $c_t = c / (t + 1)^\beta$ ; 更新参数集  $\theta_{t-1}^{\pm} = \{\theta_{p(k),t} \pm c_t \cup \theta_{p(k),t}\}$ , 式中  $\theta_{t-1}^{\pm}$  表示对参数  $\theta_{p(k),t}$  扰动后的系统参数; 采样  $x_+^{(i)} \sim p_{\theta+t-1}(x_t | x_{t-1}^{(i)})$ ,  $x_-^{(i)} \sim p_{\theta-t-1}(x_t | x_{t-1}^{(i)})$ ; 计算目标函数  $h(\theta_{t-1}^+) = \sum_{i=1}^N \omega_{t-1}^{(i)} p_{\theta+t-1}(y_t | x_+^{(i)})$ ,  $h(\theta_{t-1}^-) = \sum_{i=1}^N \omega_{t-1}^{(i)} p_{\theta-t-1}(y_t | x_-^{(i)})$ ; 计算梯度  $\nabla h(\theta_{t-1}^{\pm}) = h(\theta_{t-1}^+) - 0.5h(\theta_{t-1}^-)c_t$ ; 参数时间更新  $\theta(j)p(k), t \sim N(\theta(j)p(k), t-1 + \lambda_t \nabla h(\theta_{t-1}^{\pm}), \sigma^2), j=1, 2, \dots, N$ 。

与 RD 相比, MRD 方法在每次迭代中, 利用量测值获得的梯度  $\nabla h(\theta_{t-1}^{\pm})$  进行参数时间更新。当  $D_\theta$

较大时, 相应的  $\nabla h(\theta_{t-1}^{\pm})$  较大, 驱使参数粒子更有效率地逼近其真实后验边缘概率密度; 当  $D_\theta$  较小时,  $\nabla h(\theta_{t-1}^{\pm})$  较小, 此时, MRD 方法近似于 RD 方法。

### 2.5 采样粒子质量改进方法

在粒子滤波器的实际运用中, 由于使用次优的重要性函数进行采样, 并没有考虑当前量测值, 在迭代的的过程中往往会出现粒子退化现象。为了解决上述问题, 常用的一种方法是在采样过程中引入优化算法, 改进采样粒子质量。粒子群优化(Particle swarm optimization, PSO)是由 Kennedy 和 Eberhart 等<sup>[14]</sup>于 1995 年提出的一类模拟群体智能行为的优化算法。由于与粒子滤波算法有很多相似性, PSO 能较易地应用到粒子滤波算法中, 提升标准滤波算法的性能。本文将 PSO 引入粒子滤波算法中, 利用最新的量测值计算适应度值, 将所有粒子向最优粒子移动, 使采样粒子集在权重值更新前趋向于高似然区域, 从而解决粒子退化问题。定义适应度函数为

$$F = \exp \left[ -\frac{1}{2Q_t} (y_t - y_{\text{pred}})^2 \right] \quad (10)$$

式中:  $Q_t$  为量测噪声;  $y_t$  为时刻  $t$  量测值;  $y_{\text{pred}}$  为时刻  $t$  预测量测值。

利用下式对采样粒子的速度和位置进行更新:

$$v_t^{(i)} = \gamma v_t + c_1 |\text{Rand } n| (p_{\text{best}} - x_t^{(i)}) + c_2 |\text{Rand } n| (p_{\text{gbest}} - x_t^{(i)}) \quad (11)$$

$$\tilde{x}_t^{(i)} = x_t^{(i)} + v_t^{(i)} \quad (12)$$

式中:  $|\text{Rand } n|$  为正的高斯分布的随机数;  $p_{\text{gbest}}$  为群体最优粒子;  $p_{\text{best}}$  为个体最优粒子;  $x_t^{(i)}$  为时刻  $t$  采样粒子;  $\tilde{x}_t^{(i)}$  为经粒子群优化后采样粒子;  $c_1, c_2$  为学习因子;  $v_t$  为初始更新速度;  $\gamma$  为惯性系数。  $\mu$  较大则算法具有较强的全局搜索能力,  $\omega$  较小则算法具有较强的局部搜索能力。

考虑到采用重采样技术, 会导致粒子多样性缺失。而且 PSO 算法中, 粒子群在追逐最优粒子的过程时, 也会表现出较强的趋同性。上述两种因素共同作用会放大样本匮乏问题, 不利于粒子滤波器逼近系统的真实后验概率分布。为了解决这个问题, 本文使用模拟退火优化算法(simulated annealing optimization, SAO)对粒子位置更新条件进行改进, 增加粒子多样性。其基本思路如下, 当优化后粒子的适应值大于当前全局最优适应值时, 则接受该粒子; 当优化后粒子的适应值小于当前全局最优适应值时, 则根据式(13)计算的模拟退火概率  $P_{\text{sa}}$  决定是否接受该粒子。

$$P_{\text{sa}} = e^{-\alpha(P_{p_{\text{gbest}}} - \tilde{\omega}_t^{(i)})^2} \quad (13)$$

式中:  $\alpha$  为退火系数, 由式(13)计算而得;  $\tilde{\omega}_t^{(i)}$  为优

化后粒子适应值,由式(14)计算而得; $P_{\rho_{\text{gbest}}}$ 为全局最优适应值。

$$\alpha = -\ln \beta / (P_{\rho_{\text{gbest}}} - \bar{\omega}_t)^2 \quad (14)$$

式中: $\beta$ 为平均权值接受率; $\bar{\omega}_t$ 为优化前采样粒子群权值的平均值。若令 $\beta = 0.5$ 为均值接受率,则式(13)含义为若新粒子权值等于原粒子集平均权值,则新粒子有50%概率被接受。通过控制 $\beta$ 可以控制退火曲线,若 $\beta$ 设置过高,则大量高权值粒子无法被接受,转而重新生成新粒子,导致计算资源浪费;若 $\beta$ 设置过低,则低权值新粒子也能轻易被接受,相当于算法失去作用,其值一般设为0.5。

$$\tilde{\omega}_t^{(i)} = \exp[-0.5(y_t - y_{\text{pred}}^{(i)})^2 Q_t] \quad (15)$$

结合 PSO 和 SA,得到一种采样粒子质量改进方法,其算法归纳如下:

1) 初始化,令当前粒子个体最优粒子  $p_{\text{best}}^{(i)} = x^{(i)}$  和权值  $P_{\rho_{\text{best}}}^{(i)} = \omega^{(i)}$ 、全局最优粒子  $p_{\text{gbest}}$  为  $P_{\rho_{\text{best}}}$  的最大值对应的粒子和权值  $P_{\rho_{\text{gbest}}}$  为  $P_{\rho_{\text{best}}}$  的最大值、

$\beta = 0.5$ ,计算权值均值 $\bar{\omega}_t$ 和退化系数 $\alpha$ 。

2) 对每个粒子  $i$  进行迭代计算。更新速率  $v_{t-1}^{(i)} = |\text{Rand } n|(p_{\text{best}} - x_{t-1}^{(i)}) + |\text{Rand } n|(p_{\text{gbest}} - x_{t-1}^{(i)})$ ;粒子位置更新 $\tilde{x}_t^{(i)} = x_{t-1}^{(i)} + v_{t-1}^{(i)}$ ;计算粒子权值 $\tilde{\omega}_t^{(i)}$ ,若 $\tilde{\omega}_t^{(i)} > P_{\rho_{\text{gbest}}}$ ,则接受该更新粒子 $\tilde{x}_t^{(i)}$ ;若 $P_{\rho_{\text{best}}} \leq \tilde{\omega}_t^{(i)} \leq P_{\rho_{\text{gbest}}}$ ,则有根据式(12)有 $P_{\text{sa}}$ 概率接受该更新粒子 $\tilde{x}_t^{(i)}$ ,此时,当选择不接受该粒子则令 $p_{\text{best}} = \tilde{x}_t^{(i)}$ ,重新进行更新速率;若 $P_{\rho_{\text{best}}} > \tilde{\omega}_t^{(i)}$ ,则有 $P_{\text{sa}}$ 概率接受该更新粒子 $\tilde{x}_t^{(i)}$ ,此时,当选择不接受该粒子,则重新进行更新速率。

3) 返回更新后粒子的位置与权值  $\{\tilde{x}_t^{(i)}, \tilde{\omega}_t^{(i)}\}$ 。

至此,在 2.3 节联合估计方案的基础上,使用 2.4 节和 2.5 节方法对其所采用的粒子滤波算法进行改进,得到本文提出的基于双重改进粒子滤波器的联合估计方案,如图 2 所示。

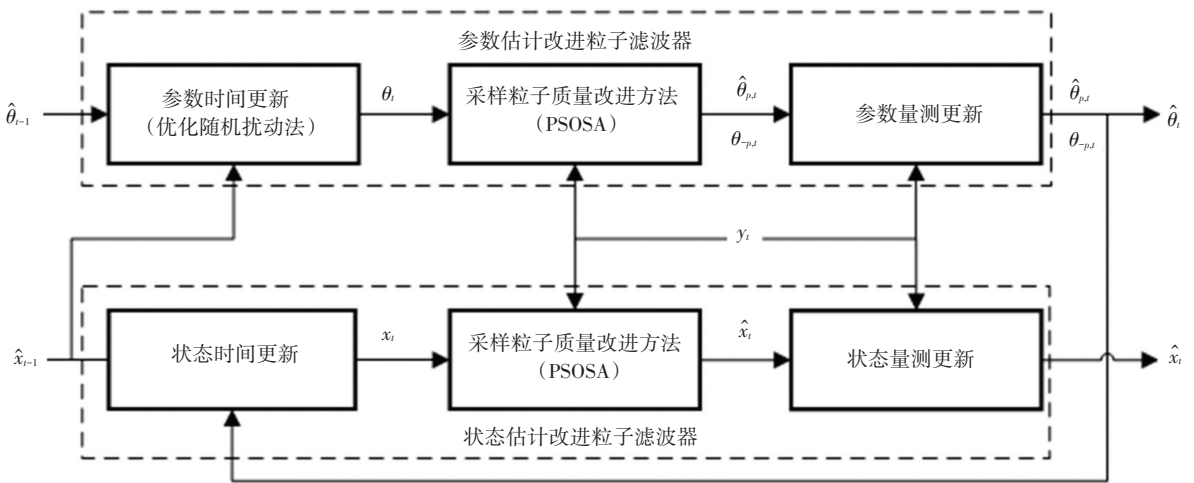


图 2 基于双重改进粒子滤波器的联合估计方案示意图

Fig.2 Joint estimation method based on dual improved particle filter

### 3 仿真验证与算法性能分析

#### 3.1 潜在故障参数集的获取

本文以某定排量变转速型电动静液作动器 (electro hydrostatic actuator, EHA) 为对象,假设系统存在参数突变型故障或参数渐变型故障,前者代表一类参数在系统工作过程中可能会发生突变的故障,如阀口堵塞而导致阀口过流系数降低等;后者代表一类参数随时间逐渐变化的故障,如缸体磨损而导致运动阻尼系数逐渐增大等,在 MATLAB/SIMULINK 仿真环境中,首先,参考文献[17]方法,搭建 EHA 动态仿真模型,部分模型参数注释及标称

值见表 2,以获取正常状态下的动态响应,分别为电枢绕组电流  $i$ 、液压泵转速  $\omega$  和液压泵进出口压差  $p$ 。然后,为了得到基于仿真模型的故障动态响应,本文设计了以下两类故障的故障注入方法。

对于参数突变型故障,在 SIMULINK 环境中,通过使用一个阶跃信号实现故障注入。本文考虑 EHA 的电机电枢绕组电阻发生参数突变型故障,定义延迟阶跃函数:

$$R_a(t) = \begin{cases} 0.36 \Omega, & 0 \leq t \leq 1.5 \text{ s} \\ 0.5 \Omega, & t > 1.5 \text{ s} \end{cases} \quad (16)$$

添加  $R_a$  突变型故障注入模块后的 EHA 电机部分仿真模型<sup>[18]</sup>如图 3 所示。

表 2 模型参数注释和标称值

Tab.2 Annotation and nominal value of model parameters

参数	物理含义	标称值
$U_s$	输入电压	270 V
$L_a$	电枢绕组电感	$1.3 \times 10^{-3}$ H
$R_a$	电枢绕组电阻	0.36 $\Omega$
$K$	电动势转矩系数	0.23 V · s/rad
$f_{mp}$	电机和液压泵的总阻尼系数	$3 \times 10^{-3}$ Nm/(r · min <sup>-1</sup> )
$J_{mp}$	电机和液压泵的总转动惯量	$1.6 \times 10^{-3}$ kg · m <sup>2</sup>
$E$	液压油弹性模量	686 MPa
$R_l$	液压泵总泄露系数	$1 \times 10^{-11}$ (m <sup>3</sup> · s <sup>-1</sup> )/Pa
$M_j$	液压缸总质量	30 kg
$F_l$	作动器负载	$1 \times 10^5$ N
$F_j$	液压缸总阻尼系数	100 N/(m · s <sup>-1</sup> )
$A$	液压缸柱塞横截面积	$6.6 \times 10^{-3}$ m <sup>2</sup>
$D_p$	液压泵排量	7.25 mL/r
$C_h$	液压泵液阻	$1 \times 10^{-2}$ Pa/m <sup>3</sup>
$V$	管路与作动筒平均容积	700 cm <sup>3</sup>
$E_f$	负载的弹性刚度	$2 \times 10^6$ N/m

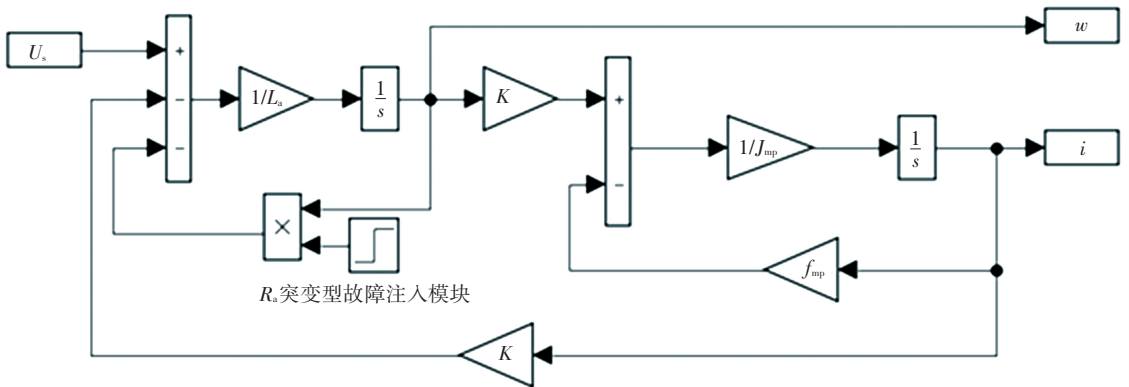


图 3 基于 SIMULINK 环境的 EHA 电机仿真模型

Fig.3 EHA motor simulation model in the environment of SIMULINK

对于参数渐变型故障,在 SIMULINK 环境中,通过使用 MATLAB-FUNCTION 来实现故障注入。本文考虑 EHA 的液压缸总阻尼系数发生参数渐变型故障,定义其退化函数为式(17)。添加  $F_j$  渐变型故障注入模块后的 EHA 负载仿真模型<sup>[19]</sup>如图 4 所示。

$$F_j(t) = \begin{cases} 100, & 0 \leq t \leq 1.5 \text{ s} \\ 100e^{0.16(t-1.5)}, & t > 1.5 \text{ s} \end{cases} \quad (17)$$

最后,根据文献[2]的 ARRFBD 方法,可推导 EHA 参数型故障诊断解析冗余关系表达式为式(18)~(20),并据此得到故障特征矩阵见表 3。

$$ARR_1 : U_s - L_a \frac{di}{dt} - R_a i - K\omega = 0 \quad (18)$$

$$ARR_2 : Ki - J_{mp} \frac{d\omega}{dt} - f_{mp}\omega - \frac{p}{D_p} = 0 \quad (19)$$

$$ARR_3 : F_j^{-1}pA^2 - D_p^{-1}F_j^{-1}M_j \frac{d\omega}{dt} + F_j^{-1}M_j C_h \frac{d^2p}{dt^2} + R_l^{-1}F_j^{-1}M_j \frac{dp}{dt} - F_j^{-1}AF_l + R_l^{-1}p + C_h \frac{dp}{dt} - D_p^{-1}\omega = 0 \quad (20)$$

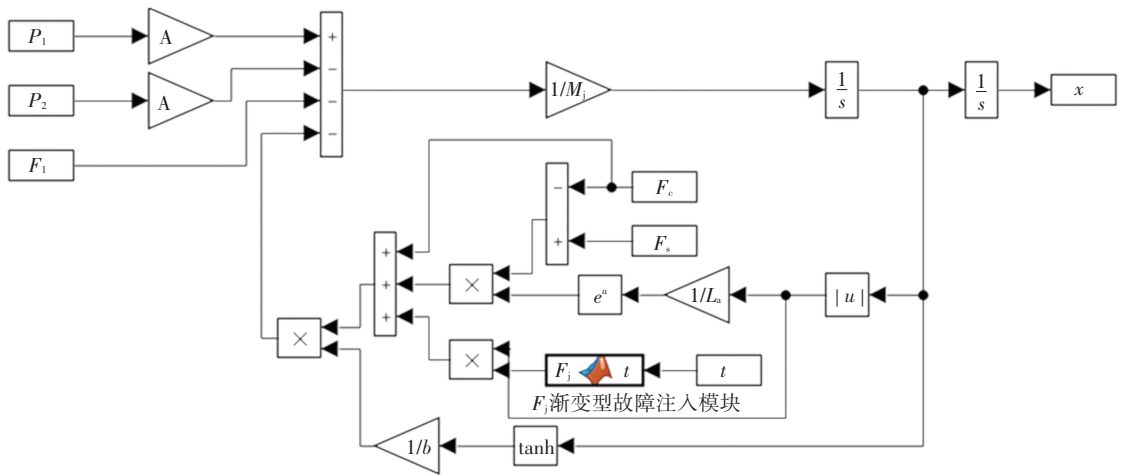


图 4 基于 SIMULINK 环境的 EHA 负载部分仿真模型

Fig.4 Load part of EHA simulation model in the environment of SIMULINK

表 3 EHA 故障特征矩阵

Tab.3 Fault characteristic matrix of EHA

参数	ARR1	ARR2	ARR3	$D_b$	$I_b$
$U_s$	1	0	0	1	0
$L_a$	1	0	0	1	0
$R_a$	1	0	0	1	0
$K$	1	1	0	1	1
$J_{mp}$	0	1	0	1	0
$f_{mp}$	0	1	0	1	0
$D_p$	0	1	1	1	1
$C_h$	0	0	1	1	0
$R_l$	0	0	1	1	0
$M_j$	0	0	1	1	0
$F_j$	0	0	1	1	0

仿真实验的硬件环境为英特尔 I5-9400 处理器,8 GB 内存),软件环境为 MATLAB 2012b。仿真模型在两类故障下,设置采样频率为 1 000 Hz、求解器为 ode45,分别运行 5 s。利用 MATLAB 工具箱的 AWGN 函数对  $i$ 、 $\omega$ 、 $p$  和  $v$  数据引入高斯白噪声,设置 SNR = 60 dB,并使用 ARBFD 进行故障诊断。对于  $R_a$  突变型故障,在诊断过程中,只有 ARR1 超过了诊断阈值。所以只展示 ARR1 诊断结果,如图 5 所示,可以观察到在 1.5 s 后,ARR1 偏离零值并超出诊断阈值。此时,根据表 3 可以推断出 PFPS 为  $\{R_a, L_a, U_s\}$ 。

而对于  $F_j$  渐变型故障,只展示 ARR3 诊断结果如图 6 所示,可以观察到在 1.5 s 后,ARR3 开始逐渐偏离零值,直到约在 2.45 s 时超出诊断阈值。此时,根据表 3 可以推断出 PFPS 为  $\{C_h, R_l, M_j, F_j\}$ 。




图 5 参数  $R_a$  突变型故障 ARR1 诊断结果

Fig.5 ARR1 results for parameter mutation fault  $R_a$




图 6 参数  $F_j$  渐变型故障 ARR3 诊断结果

Fig.6 ARR3 results for parameter gradient fault  $F_j$

### 3.2 参数突变型故障隔离仿真结果与分析

为了验证本文提出的基于双重粒子滤波器的联合估计模型对解决故障隔离问题的有效性和优越性。分别采用文献[15]的基于扩展状态空间的粒子滤波器联合估计模型(extend particle filter,EPF)和本文提出的 DPF,对 PFPS 进行故障隔离仿真对比分析。同时,为了验证本文所提出两种改进方法的优越性,本文在基于双重粒子滤波器的联合估计

模型中,采用4种基于不同优化思想的采样粒子质量改进方法的粒子滤波器和两种参数时间更新方法进行仿真对比分析。其中所采用的4种粒子滤波器分别为标准PF(记为PF)、文献[13]中的遗传算法优化PF(记为GA-PF)、文献[14]中的生物地理学优化PF(记为BBO-PF)和本文PSOSA-PF。两种参数更新方法分别为文献[15]中的随机扰动法,记为RD和本文提出的MRD。

本文采用状态平均有效粒子数  $\overline{N_{\text{eff},x}}$  和状态均方根误差  $\text{RMSE}_x$  两个性能指标对状态估计效果进行评价;采用参数平均有效粒子数  $\overline{N_{\text{eff},\theta}}$ 、参数收敛时间  $t_c$ 、参数平均收敛值  $\theta_c$  和参数估计相对误差率  $e_{\theta,c}$  4个性能指标对突变型故障参数估计效果进行评价;采用参数平均有效粒子数  $\overline{N_{\text{eff},\theta}}$ 、参数均方根误差  $\text{RMSE}_\theta$  两个性能指标对渐变型故障参数估计效果进行评价。以状态估计为例,  $\text{RMSE}_x$  计算公式为式(21),  $\overline{N_{\text{eff},x}}$  计算公式为式(22)。

$$\text{RMSE}_x = \left[ \frac{1}{N_T} \sum_{t=1}^{N_T} (x_t - \hat{x}_t)^2 \right]^{0.5} \quad (21)$$

$$\overline{N_{\text{eff},x}} = \frac{1}{N_T} \sum_{t=1}^{N_T} \left[ 1 / \sum_{i=1}^N (\omega_i^{(t)})^2 \right] \quad (22)$$

式中:  $N_T$  为样本数量;  $N$  为粒子数量。

得到PFPS为  $\{R_a, L_a, U_s\}$  后,令代估状态变量集为  $\{x_1, x_2, x_3, x_4, x_5, x_6\} = \{i, di/dt, \omega, d\omega/dt, p, dp/dt\}$ ,令代估参数变量集为  $\{x_7, x_8, x_9\} = \{R_a, L_a, U_s\}$ ,则根据式(18)~(20),可得如下离散随机时间模型:

$$\begin{cases} x_1(t) = x_1(t-1) + x_2(t-1) \cdot T + Q_\mu \\ x_2(t) = (x_9(t) - x_7(t) \cdot x_1(t-1) - K \cdot x_3(t-1)) / x_8(t) + Q_\mu \\ x_3(t) = x_3(t-1) + x_4(t-1) \cdot T + Q_\mu \\ x_4(t) = (K \cdot x_1(t-1) - f_{\text{mp}} \cdot x_3(t-1) - x_5(t-1) / D_p) / J_{\text{mp}} + Q_\mu \\ x_5(t) = x_5(t-1) + x_6(t-1) \cdot T + Q_\mu \\ x_6(t) = (F_j^{-1} \cdot x_5(t-1) \cdot A^2 - D_p^{-1} \cdot F_j^{-1} \cdot M_j \cdot x_4(t-1) + R_1^{-1} \cdot F_j^{-1} \cdot M_j \cdot x_6(t-1) - F_j^{-1} \cdot A \cdot F_1 + R_1^{-1} \cdot x_5(t-1) + C_h \cdot x_6(t-1) - D_p^{-1} \cdot x_3(t-1)) \cdot T / (F_j^{-1} \cdot M_j \cdot C_h) + Q_\mu \end{cases} \quad (23)$$

首先,分别调用DPF和EPF对状态变量集和PFPS进行联合估计。此时,联合估计模型内均采用本文提出PSOSA-PF和MRD,且粒子数均为100。

图7是在系统过程噪音方差  $Q_\mu = 1$ 、量测噪音方差  $Q_v = 10$ ,使用DPF和EPF得到的参数  $R_a$  估计效果图。如图5所示,滤波器在1.5 s处开始工作,参数估计结果显示  $R_a$  估计值偏离标称值,可以判断故障发生在  $R_a$ ,实现参数型故障隔离。其次,DPF方法得到的参数收敛值与预设值基本一致,但EPF方法得到的参数收敛值与预设值存在一定偏差;另一方面,使用DPF方法得到的  $R_a$  估计值在  $t_c = 2.03$  s开始收敛,而EPF方法在  $t_c = 3.63$  s时才开始收敛。联合估计仿真结果汇总见表4,结果表明,对于参数突变型故障,DPF参数估计抗干扰能力更强、收敛速度更快且每次迭代运行时间更短。




图7 参数  $R_a$  估计效果图

Fig.7 Parameter estimation results for  $R_a$

然后,在DPF中,分别调用4种粒子滤波器和两种参数时间更新方法进行联合估计。设置  $Q_\mu = 1$ 、 $Q_v = 10$ 、 $\lambda = 0.005$ 、 $c = 1$  和  $\sigma = 1 \times 10^{-3}$ ,且各算法中粒子数  $N$  均为100。仿真结果汇总见表5,其中每种方法共运行1000次,统计指标结果的平均值。表5中,对于参数突变型故障,一方面,在使用同一种参数时间更新方法时,PSOSA-PF相较于其他粒子滤波,其  $\overline{N_{\text{eff},x}}$  和  $\overline{N_{\text{eff},\theta}}$  更多,说明本文方法能更有效地抑制粒子退化现象;其  $\text{RMSE}_x$  和  $e_{\theta,c}$  更低,说明其能更准确地对状态实现跟踪估计,有利于提升参数粒子滤波器性能,进而提升参数估计精度;此外,相对于所列举的改进粒子滤波器,其迭代所需运行时间最少。另一方面,在使用同一种粒子滤波器时,虽然使用MRD方法会增加每次迭代时算法的运行时间,但由于MRD能显著地提升参数收敛速度,使得所需迭代次数减少。如同样采用PSOSA-PF,使用RD方法达到参数收敛状态需要运行总时间为迭代运行时间乘以滤波器开始工作直到参数收敛所需要的迭代数,为6.318 s,而使用MRD方法则为2.544 s。所以,整体而言,MRD计算效率更高。

表 4 参数突变型故障下 DPF 与 EPF 联合估计仿真结果

Tab.4 Joint estimation simulation results by DPF and EPF algorithms under parameter mutation fault

参数估计方法	状态估计		参数估计			迭代运行 时间/ms	
	$\overline{N_{eff_x}}$	RMSE <sub>x</sub>	$\overline{N_{eff_\theta}}$	$t_c$ /s	$\theta_c$		$e_{\theta_c}$ /%
DPF	32.82	1.47	26.49	2.03	0.505	1.0	4.8
EPF	30.24	1.56	24.03	3.63	0.512	2.4	6.2

注:  $\theta_c$  为  $t_c$  后的平均值。

表 5 参数突变型故障下 4 种滤波器及两种参数时间更新方法的联合估计仿真结果

Tab.5 Joint estimation simulation results by four filters and two parameter time update methods under parameter mutation fault

所选滤波器 (参数时间更新方法)	状态估计		参数估计			迭代运行 时间/ms	
	$\overline{N_{eff_x}}$	RMSE <sub>x</sub>	$\overline{N_{eff_\theta}}$	$t_c$ /s	$\theta_c$		$e_{\theta_c}$ /%
PF (RD)	25.33	2.69	19.32	4.33	0.513	2.6	2.5
GA-PF (RD)	29.54	2.34	22.59	3.59	0.509	1.8	4.7
BBO-PF (RD)	29.88	2.03	21.64	3.67	0.512	2.4	4.5
PSOSA-PF (RD)	31.12	1.78	23.59	3.12	0.508	1.6	3.9
PF (MRD)	26.12	2.58	21.64	3.77	0.514	2.8	3.3
GA-PF (MRD)	30.64	1.85	23.77	3.03	0.507	1.4	5.7
BBO-PF (MRD)	31.77	1.64	23.64	2.89	0.513	2.6	5.3
PSOSA-PF (MRD)	32.82	1.47	26.49	2.03	0.505	1.0	4.8

注:  $t_c$  可反映联合估计算法所需迭代次数,而非非联合估计算法实际运行时间。

### 3.3 参数渐变型故障隔离仿真结果与分析

得到 PFPS 为  $\{C_h, R_1, M_j, F_j\}$  后,处理方法同 3.2 节,图 8 为使用 DPF 和 EPF 得到的参数  $F_j$  估计效果图。如图 8 所示,首先,参数估计结果显示  $F_j$  估计值偏离标称值,可以判断故障发生在  $F_j$ ,实现参数型故障隔离。其次,DPF 参数估计曲线以 3 005 ms、EPF 参数估计曲线以 3 463 ms 为界分为两个阶段。在第一个阶段中,由于故障被检测到时,参数退化已经进行了一段时间,所以滤波器工作时使用的初始值(标称值)与参数真实值之间存在一定差距,类似突变型故障参数估计;随着参数估计值与真实值逐渐接近,在第二个阶段中,滤波器对参数进行跟踪估计。

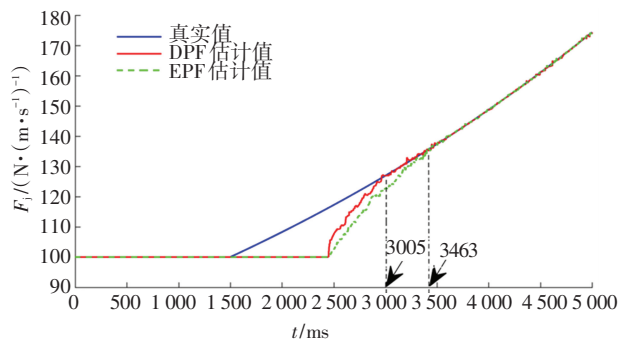


图 8 参数  $F_j$  估计效果图

Fig.8 Parameter estimation results for  $F_j$

显然,DPF 和 EPF 在第二阶段都能实现对参数的准确跟踪,但在第一阶段,DPF 能更快地接近当前参数真实值,意味着 DPF 会得到更小的 RMSE<sub>θ</sub>。

联合估计仿真结果汇总见表 6,可以看出采用 DPF 参数估计精度和计算速度较 EPF 更优。

此外,设置  $Q_\mu = 1, Q_v = 10, \lambda = 0.05, c = 1$  和  $\sigma = 0.1$ ,各算法中粒子数  $N$  均为 100。表 7 为联合估计仿真对比结果。如表 7 所示,在使用同一种参数时间更新方法时,与节 3.3 结果一样,本文提出的 PSOSA-PF 相对于其他改进粒子滤波器性能更具优势。值得注意的是,在  $N = 100$  时,虽然使用 MRD 能较使用 RD 得到更多的  $\overline{N_{eff_\theta}}$  和更低的 RMSE<sub>θ</sub>,但相应地需要消耗更多的计算资源。考虑到 RD 的性能依赖于粒子数量,在使用 RD 时适当增加粒子数量,可以进一步对比两种方法的计算效率。表 8 为在 PSOSA-PF (RD) 下,采用不同数量的粒子数的联合估计仿真结果。可以看出,使用 RD 时增加粒子数量,可以提升其性能,得到更多的  $\overline{N_{eff_\theta}}$  和更低的 RMSE<sub>θ</sub>,但同样需要消耗更多的计算资源。对比表 7 可知,当  $N = 400$  时使用 RD,与  $N = 100$  时使用 MRD 所得的 RMSE<sub>θ</sub> 和  $\overline{N_{eff_\theta}}$  相接近,但是使用 RD 所需要的迭代运行时间更长,即 MRD 方法计算效率更高。

表 6 参数渐变型故障下 DPF 与 EPF 联合估计仿真结果

Tab.6 Joint estimation simulation results by DPF and EPF algorithms under parameter gradient fault

参数估计方法	状态估计		参数估计		迭代运行 时间/ms
	$\overline{N_{\text{eff}x}}$	RMSE <sub>x</sub>	$\overline{N_{\text{eff}\theta}}$	RMSE <sub>θ</sub>	
DPF	31.97	1.55	24.57	4.34	0.005 8
EPF	29.08	1.76	22.84	5.98	0.007 7

表 7 参数渐变型故障下 4 种滤波器及两种参数时间更新方法的联合估计仿真结果

Tab.7 Joint estimation simulation results by four filters and two parameter time update methods under parameter gradient fault

所选滤波器 (参数时间更新方法)	状态估计		参数估计		迭代运行 时间/ms
	$\overline{N_{\text{eff}x}}$	RMSE <sub>x</sub>	$\overline{N_{\text{eff}\theta}}$	RMSE <sub>θ</sub>	
PF(RD)	24.27	2.69	16.71	7.28	2.8
GA-PF(RD)	27.45	2.12	19.55	5.97	5.9
BBO-PF(RD)	27.62	2.18	19.08	6.12	5.7
PSOSA-PF(RD)	29.84	1.77	21.39	5.29	4.6
PF(MRD)	25.62	2.36	18.24	6.34	3.9
GA-PF(MRD)	28.75	1.94	22.46	4.67	7.2
BBO-PF(MRD)	28.91	1.85	22.09	4.88	6.7
PSOSA-PF(MRD)	31.97	1.55	24.57	4.34	5.8

表 8 PSOSA-PF(RD) 中采用不同粒子数量的联合估计仿真结果

Tab.8 Joint estimation simulation results by PSOSA-PF(RD) algorithm with different numbers of particles

粒子数	状态估计		参数估计		迭代运行 时间/ms
	$\overline{N_{\text{eff}x}}$	RMSE <sub>x</sub>	$\overline{N_{\text{eff}\theta}}$	RMSE <sub>θ</sub>	
100	29.84	1.77	21.39	5.29	4.6
200	30.47	1.71	22.49	4.89	6.1
300	31.13	1.65	23.56	4.64	7.5
400	31.88	1.57	24.61	4.37	9.2
500	32.37	1.52	25.34	4.12	9.7

## 4 结 论

本文针对基于解析冗余关系的故障诊断应用中难以实现故障隔离的问题,提出了一种基于双重改进粒子滤波器的状态和参数联合估计方法来实现参数型故障隔离,并在 MATLAB/SIMULINK 环境下,对 EHA 进行参数突变型和参数渐变型故障隔离仿真实验。主要结论如下:

1) 在本文假设的两类参数型故障下,DPF 在鲁棒性、计算速度和估计精度上均优于 EPF,更适合用以解决本文提出的故障隔离问题。

2) 本文提出的改进方法(PSOSA-PF(MRD))能显著提升 DPF 性能,进而提升参数估计精度与计算效率。其较使用传统方法(PF(RD)),对于参数突变型故障,参数收敛所需迭代数减少了 81.5%、参数收敛所需总运行时间降低了 64% 和参数估计相对

误差降低了 1.6%;而对于参数渐变型故障,参数均方根误差降低了 40.3%。

综上,本文提出的基于双重改进粒子滤波器的联合估计方法基本满足参数型故障隔离对估计精度和计算的要求,可作为基于解析冗余关系故障诊断中的故障隔离方法。

## 参 考 文 献

[1] 周东华, 胡艳艳. 动态系统的故障诊断技术[J]. 自动化学报, 2009, 35(6):748  
 ZHOU Donghua, HU Yanyan. Fault diagnosis techniques for dynamic systems[J]. Acta Automatica Sinica, 2009, 35(6):748. DOI: 10.3724/SP.J.1004.2009.00748

[2] DJEZIRI M A, BOUAMAMA B O, MERZOUKI R. Modelling and robust FDI of steam generator using uncertain bond graph model[J]. Journal of Process Control, 2009, 19(1):149. DOI: 10.1016/j.jprocont.2007.12.009

[3] YU Ming, WANG Danwei, LUO Ming. Prognosis of hybrid systems

- with multiple incipient faults: augmented global analytical redundancy relations approach[J]. *IEEE Transactions on Systems, Man, and Cybernetics—Part A: Systems and Humans*, 2011, 41(3):540. DOI: 10.1109/TSMCA.2010.2076396
- [4] HUANG Jie, AN Honglei, LANG Lin, et al. A data-driven multi-scale online joint estimation of states and parameters for electro-hydraulic actuator in legged robot[J]. *IEEE Access*, 2020, 8:36885. DOI: 10.1109/ACCESS.2020.2974984
- [5] BIAN Xiaomeng, LI X R, CHEN Huimin, et al. Joint estimation of state and parameter with synchrophasors—Part I: state tracking[J]. *IEEE Transactions on Power Systems*, 2011, 26(3):1196. DOI: 10.1109/TPWRS.2010.2098422
- [6] BIAN Xiaomeng, LI X R, CHEN Huimin, et al. Joint estimation of state and parameter with synchrophasors—Part II: parameter tracking[J]. *IEEE Transactions on Power Systems*, 2011, 26(3):1209. DOI: 10.1109/TPWRS.2010.2098423
- [7] CHOI K R, PARK C G. Design of fault isolator of satellite reaction wheel system using dual filter and multi-hypothesis extended Kalman filter[J]. *Journal of the Korean Society for Aeronautical and Space Sciences*, 2009, 37(12):1225. DOI: 10.5139/JKSAS.2009.37.12.1225
- [8] DAROOGHEH N, MESKIN N, KHORASANI K. A dual particle filter-based fault diagnosis scheme for nonlinear systems[J]. *IEEE Transactions on Control Systems Technology*, 2018, 26(4):1317. DOI: 10.1109/TCST.2017.2705056
- [9] KARLSSON R, SCHON T, GUSTAFSSON F. Complexity analysis of the marginalized particle filter[J]. *IEEE Transactions on Signal Processing*, 2005, 53(11):4408. DOI: 10.1109/TSP.2005.857061
- [10] VAFAMAND N, SAFARINEJADIAN B. State and parameter estimation of CSTR using joint-UKF[C]// *International Conference on Control, Instrumentation, and Automation*. Tehran: IEEE, 2013: 165. DOI: 10.1109/ICCIAutom.2013.6912828
- [11] BERZUINI C, BEST N G, GILKS W R, et al. Dynamic conditional independence models and Markov chain Monte Carlo methods[J]. *Journal of the American Statistical Association*, 1997, 92(440):1403. DOI: 10.2307/2965410
- [12] 孟庆旭. 粒子滤波算法研究及其在非线形估计中的应用[D]. 武汉:华中科技大学, 2019
- MENG Qingxu. Research on particle filtering algorithm and its application in nonlinear estimation[D]. Wuhan: Huazhong University of Science & Technology, 2019
- [13] QIU Zhenbing, QIAN Huaming. Adaptive genetic particle filter and its application to attitude estimation system[J]. *Digital Signal Processing*, 2018, 81:163. DOI:10.1016/j.dsp.2018.06.015
- [14] 方正, 佟国峰, 徐心和. 粒子群优化粒子滤波方法[J]. *控制与决策*, 2007, 22(3):273
- FANG Zheng, TONG Guofeng, XU Xinhe. Particle swarm optimized particle filter[J]. *Control and Decision*, 2007, 22(3):273. DOI: 10.3321/j.issn:1001-0920.2007.03.007
- [15] YU Ming, LAN Dun, JIANG Canghua, et al. Hybrid condition monitoring of nonlinear mechatronic system using biogeography based optimization particle filter and optimized extreme learning machine [J]. *ISA Transactions*, 2021, 120:342. DOI: 10.1016/j.isatra.2021.03.018
- [16] YANG Xiaojun, SHI Kunlin, HUANG Tao, et al. Combine parameter and state estimation in particle filtering[C]// *IEEE International Conference on Control and Automation*. Guangzhou: IEEE, 2007: 1036. DOI:10.1109/ICCA.2007.4376514
- [17] SONG Jixin, YU Liming, HAN Xudong, et al. Modeling and simulation of redundancy management of electro-hydrostatic actuator [C]// JIA Y, ZHANG W, FU Y. *Proceedings of 2020 Chinese Intelligent Systems Conference*. Singapore: Springer, 2021:542. DOI: 10.1007/978-981-15-8458-9\_58
- [18] 康荣杰, 焦宗夏, MARE J C, 等. 电动静液作动器非线性框图建模与鲁棒控制方法[J]. *航空学报*, 2009, 30(3):518
- KANG Rongjie, JIAO Zongxia, MARE J C, et al. Nonlinear block diagram model and robust control of electro-hydrostatic actuator[J]. *Acta Aeronautica et Astronautica Sinica*, 2009, 30(3):518. DOI: 10.3321/j.issn:1000-6893.2009.03.020
- [19] SPALL J C. Implementation of the simultaneous perturbation algorithm for stochastic optimization[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1998, 34(3):817. DOI: 10.1109/7.705889

(编辑 魏希柱)