

http://bhxb.buaa.edu.cn jbuua@buaa.edu.cn

DOI: 10.13700/j.bh.1001-5965.2019.0526

# 基于修正 IMM 的风机变桨系统故障诊断方法

王进花<sup>1 2 3 \*</sup>, 朱恩昌<sup>1 2</sup>, 曹洁<sup>1 2</sup>, 余萍<sup>1 2 3</sup>

(1. 兰州理工大学 电气工程与信息工程学院, 兰州 730050; 2. 甘肃省工业过程先进控制重点实验室, 兰州 730050;

3. 兰州理工大学 电气与控制工程国家级实验教学示范中心, 兰州 730050)

**摘 要:** 针对交互式多模型(IMM)故障诊断方法固定模型转移概率导致的诊断准确性、速度下降和估计精度损失问题,提出了一种基于模型转移概率和模型概率修正的故障诊断方法,并与粒子滤波(PF)结合实现了风机变桨系统传感器的多故障诊断。在非模式切换阶段,采用后验模型概率梯度信息设计模型转移概率的修正函数,以抑制噪声对 IMM 估计精度的影响;在模式切换阶段,采用模型概率反转的策略快速切换模型,弥补模型软切换导致的诊断延迟和错误诊断。通过仿真实验证明所提方法的准确性、模型切换速度以及状态估计精度都得到了较好的提升。

**关键词:** 风电机组; 变桨距系统; 故障诊断; 交互式多模型(IMM); 粒子滤波(PF); 模型转移概率

中图分类号: TP277

文献标志码: A 文章编号: 1001-5965(2020)08-1460-09

风能的开发和利用近些年正处于一个快速上升阶段<sup>[1]</sup>。风力发电机是风能转换电能的重要设备,其中的变桨子系统在维持风机的功率输出稳定和运行安全上起着重要的作用。

相对于发电机、齿轮箱等其他子系统,变桨系统故障诊断方法的研究起步较晚,但近几年国内外学者相继做出了许多尝试。文献[2]采用多胞形未知输入观测器解耦干扰,利用其生成残差检测变桨执行器卡死故障。文献[3]引入了一个故障指示因子来表征变桨执行器参数故障的缓变程度,并设计自适应观测器来估计指示因子。文献[4]使用变遗忘因子递推最小二乘法对变桨执行器故障参数进行辨识实现诊断。文献[5]设计激励信号通过频域分析检测并隔离了早期执行器缓变故障。文献[6]设计观测器,并设计检测阈值,实现了变桨传感器缓变故障的检测。文献[7]

设计多新息观测器与实际系统生成残差,实现了变桨传感器的恒增益和卡死故障的故障检测。上述文献对执行器缓变故障、卡死故障和部分传感器故障进行了初步的故障诊断研究,但对于变桨系统传感器的多故障的检测和分离问题的研究目前还很少。文献[8]验证了多模型自适应估计(MMAE)与扩展卡尔曼滤波(EKF)结合方法对电动变桨系统的不同传感器故障检测和分离的有效性,但其故障诊断准确度还有待进一步提升。

动态系统的故障诊断问题可抽象成一个混杂系统的估计问题<sup>[9]</sup>,即通过连续的系统输入输出来估计出系统当前的离散的工作模式或故障模式。本文变桨系统的传感器多故障诊断问题正是基于这种思路,建立不同的传感器故障模型并通过自适应估计来识别这些模型。交互式多模型(IMM)是一种经典的混杂系统状态估计方法,建

收稿日期: 2019-09-26; 录用日期: 2019-11-17; 网络出版时间: 2019-11-27 13:08

网络出版地址: [kns.cnki.net/kcms/detail/11.2625.V.20191127.1150.001.html](http://kns.cnki.net/kcms/detail/11.2625.V.20191127.1150.001.html)

基金项目: 国家自然科学基金(61763028); 甘肃省自然科学基金(1506RJZA105)

\* 通信作者: E-mail: wjh0615@lut.edu.cn

引用格式: 王进花,朱恩昌,曹洁,等. 基于修正 IMM 的风机变桨系统故障诊断方法[J]. 北京航空航天大学学报,2020,46(8): 1460-1468. WANG J H, ZHU E C, CAO J, et al. Fault diagnosis method for wind turbine pitch system based on modified IMM [J]. Journal of Beijing University of Aeronautics and Astronautics, 2020, 46(8): 1460-1468 (in Chinese).

立适当的模型集,集成多个滤波器进行状态估计<sup>[10]</sup>。通过模型概率的计算获得当前与实际系统最匹配的模型,IMM 可以完成多故障的检测与隔离,并能同时进行系统状态的估计。由于加入了交互环节,相较于 MMAE 等一般多模型方法,IMM 方法有更好的模型识别能力和状态估计精度,得到了广泛的应用。文献[11]将改进的平滑变结构滤波器与 IMM 结合对一类航天器的执行器参数故障实现了分离。文献[12]利用异步传感器融合改进 IMM 结合卡尔曼滤波方法(IMM-KF)完成了高速列车的牵引逆变器多个绝缘栅双极型晶体管(IGBT)开关管的开路故障的故障检测和多故障定位分离。但是没有考虑到 IMM 本身的模型转移概率对故障诊断性能的影响。文献[13]采用 IMM-KF 对车辆垂向减振器不同程度的参数故障实现了分离,并分析了不精确模型转移概率会降低故障诊断结果的精度,但是并没有提出有效的解决方法。文献[14]采用模型概率变化的后验信息设计修正函数来在线修正 IMM 的模型转移概率。文献[15]则采用模型似然函数值进行模型转移概率矩阵的修正函数设计,同时保持主对角元素占优,一定程度上缓解了过度修正导致的模型切换速度下降。但是由于模型概率由模型转移概率进行引导,系统模式的切换是一种软切换,会导致一定的诊断延迟和诊断错误。

针对 IMM 故障诊断中固定模型转移概率导致的诊断准确性、速度下降和估计精度损失问题,本文引入粒子滤波(PF)方法和 IMM 方法对包含传感器多种故障的风机变桨系统进行故障诊断和自适应估计;在非模式切换阶段对 IMM 的模型转移概率进行自适应修正,提高方法的状态估计精度;在模式切换阶段使用反转策略修正模型概率,以提高诊断速度和减少模型失配,进而提高诊断的准确性。

### 1 系统描述

本文中采用 Odgaard 等提出的 4.8 MW 风机基准模型<sup>[16]</sup>,其中各子系统之间的关系如图 1 所示,图中:  $\beta$  和  $\beta_r$  分别为桨距角和其参考值;  $\omega_r$  和  $\omega_g$  分别为转子和发电机的转速;  $\tau_g$ 、 $\tau_r$  和  $\tau_{gr}$  分别为发电机转矩、转子转矩和发电机转矩参考值;  $P_r$  和  $P_g$  分别为发电机输出功率参考值和实际值;  $V_w$  为风速。风电机组系统由控制器、变桨系统、空气动力学系统、传动系统、发电机与变换器几部分组成。

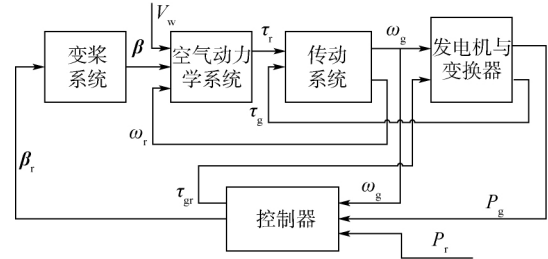


图 1 基准模型子系统原理图

Fig.1 Schematic diagram of benchmark model subsystem

变桨系统由 3 个独立控制的液压伺服执行机构组成,控制器分别对 3 个液压伺服执行机构提供电流信号来进行叶片桨距角的控制,以在高速的工况下维持发电机的额定转速和恒定功率输出。其中一个独立的变桨执行器被建模成一个二阶动态系统:

$$\frac{\beta_i(s)}{\beta_{r,i}(s)} = \frac{\omega_n^2}{s^2 + 2\xi\omega_n s + \omega_n^2} \tag{1}$$

式中:  $\beta_i(s)$  和  $\beta_{r,i}(s)$  分别为第  $i$  个叶片的桨距角和其参考值;  $\xi$  为阻尼系数;  $\omega_n$  为自然频率。

将式(1)转化为状态空间方程形式,利用欧拉法进行离散化,并加入过程噪声、量测噪声和传感器故障得到式(2)所示的离散状态空间方程:

$$\begin{cases} x_{k+1} = f(x_k, u_k) + w_k \\ y_k = h(x_k, u_k) + f_{s,k} + v_k \end{cases} \tag{2}$$

式中:  $x_k$ 、 $u_k$ 、 $w_k$ 、 $y_k$  和  $v_k$  分别为状态变量、输入变量、过程噪声、输出变量和量测噪声;  $f_{s,k}$  为  $k$  时刻的故障模型;  $f(\cdot)$  和  $h(\cdot)$  分别为系统动态方程和观测方程。变桨系统由于频繁的动作和恶劣的工况,会因为一些机械、电气或环境因素导致传感器故障<sup>[8]</sup>,传感器故障主要分为恒增益、恒偏差、卡死等故障。为了模拟发生某个传感器故障,需建立相应数学模型并于特定时间在仿真系统中注入这些故障。表 1 列出了 4 种传感器故障模型。

表 1 传感器故障模型

Table 1 Sensor failure models

模型	传感器故障类型	故障建模
$M_1$	正常	$f_{s,k} = 0$
$M_2$	恒增益	$f_{s,k} = \beta_{bias}$
$M_3$	恒偏差	$f_{s,k} = -h(\cdot) + k_{gain}h(\cdot)$
$M_4$	卡死	$f_{s,k} = -h(\cdot) + \beta_{fixed} - v_k$

注:  $\beta_{bias}$ 、 $k_{gain}$  和  $\beta_{fixed}$  分别为桨距角测量偏差值、增益系数和固定值。

### 2 基于修正 IMM-PF 的故障诊断

根据式(2)和表 1 所建立的变桨系统和  $M_1 \sim$

$M_i$  故障模型可以建立相应的滤波器,通过交互使各滤波器之间共享历史信息,各滤波器并行估计并根据似然函数更新各模型的概率,最后利用模型概率进行状态的融合输出和模型的识别,即完成状态估计和故障诊断。IMM 集成多个子滤波器来获得系统的状态估计,其中滤波器一般根据实际系统的情况进行选择。对于变桨系统,由于建模误差、风速扰动和噪声的复杂性,其模型的过程噪声通常呈现为非高斯分布<sup>[17]</sup>,因此本文采用 PF 作为 IMM 中的次优滤波器。

2.1 IMM-PF 故障诊断方法

基于 IMM 的故障诊断方法,每个迭代周期内主要包含 4 个步骤。

步骤 1 输入交互。

IMM 与 PF 结合时,交互和融合有多种方式,分别为模型层面的交互融合、粒子层面的交互融合以及粒子层面的交互和模型层面的融合。文献 [18]对以上 3 种 IMM 与 PF 结合方式进行了实验,结果显示第 1 种方式的目标跟踪性能最优,因此本文采用了此种方式。

输入交互就是在迭代周期的开始对各滤波器上一时刻的输出进行交互得到当前时刻的输入进行迭代,交互过程由式(3)~式(7)定义。

$$\hat{x}_{k-1}^{0j} = \sum_{i=1}^M \mu_{k-1}^{i|j} \hat{x}_{k-1}^i \quad (3)$$

$$P_{k-1}^{0j} = \sum_{i=1}^M \mu_{k-1}^{i|j} (P_{k-1}^i + \Delta \hat{x}^{i|j}) \quad (4)$$

$$\Delta \hat{x}^{i|j} = [\hat{x}_{k-1}^i - \hat{x}_{k-1}^{0j}] [\hat{x}_{k-1}^i - \hat{x}_{k-1}^{0j}]^T \quad (5)$$

$$\mu_{k-1}^{i|j} = \frac{\pi_{ij,k-1} \mu_{k-1}^i}{\bar{c}^j} \quad (6)$$

$$\bar{c}^j = \sum_{i=1}^M \pi_{ij,k-1} \mu_{k-1}^i \quad (7)$$

式中:  $\hat{x}_{k-1}^i$ 、 $P_{k-1}^i$  分别为  $k-1$  时刻模型  $i$  的粒子滤波器输出的估计值和协方差矩阵,  $i, j \in M$ ,  $M$  为模型集;  $\hat{x}_{k-1}^{0j}$  和  $P_{k-1}^{0j}$  分别为  $k-1$  时刻模型  $j$  在迭代周期一开始的估计交互值和协方差矩阵交互值;  $\mu_{k-1}^i$  为  $k-1$  时刻模型  $i$  的模型概率;  $\mu_{k-1}^{i|j}$  为  $k-1$  时刻模型  $i$  与模型  $j$  的交互概率;  $\pi_{ij,k-1}$  为  $k-1$  时刻模型  $i$  到模型  $j$  的模型转移概率矩阵;  $\Delta \hat{x}^{i|j}$  为  $\hat{x}_{k-1}^i$  与  $\hat{x}_{k-1}^{0j}$  之间的欧氏距离。

步骤 2 并行滤波。

根据步骤 1 的交互值  $\hat{x}_{k-1}^{0j}$  和  $P_{k-1}^{0j}$  生成对应滤波器的粒子集  $\{x_{i,k-1}^j, i=1, 2, \dots, N\}$ ,  $N$  为粒子数。

$$x_{i,k-1}^j = \hat{x}_{k-1}^{0j} + \sqrt{P_{k-1}^{0j}} \cdot \text{rand} \quad j = 1, 2, \dots, r \quad (8)$$

式中: rand 为随机函数。

根据建议分布进行重要性采样得到粒子的预测值:

$$\hat{x}_{i,k}^j = f(x_{i,k-1}^j, \mu_{k-1}) + w_{k-1} \quad (9)$$

根据观测值计算残差,用残差计算粒子权值,并归一化。

$$e_{i,k}^j = z_k - (h(x_{i,k}^j, \mu_k) + f_{s,k}^j) \quad (10)$$

$$q_{i,k}^j = \frac{1}{\sqrt{2\pi R}} \exp\left(-\frac{e_{i,k}^j R^{-1} (e_{i,k}^j)^T}{2}\right) \quad (11)$$

$$(q_{i,k}^j)^{\wedge} = \frac{q_{i,k}^j}{\sum_{i=1}^N q_{i,k}^j} \quad (12)$$

式中:  $e_{i,k}^j$  为残差;  $(q_{i,k}^j)^{\wedge}$  为归一化后的粒子权值;  $R$  为量测噪声方差;  $z_k$  为  $k$  时刻的观测值。利用计算得到的粒子权值根据残差重采样方法进行重采样,得到新的粒子集合  $\{(x_{i,k}^j, 1/N), i=1, 2, \dots, N\}$ 。将粒子的均值作为输出:

$$\hat{x}_k^j = \frac{\sum_{i=1}^N x_{i,k}^j}{N} \quad (13)$$

其后分别计算 IMM 迭代周期需要的误差协方差矩阵  $P_k^i$ 、估计残差  $e_k^j$  和残差方差矩阵  $S_k^i$  分别为

$$P_k^i = \sum_{i=1}^N \frac{(\hat{x}_{i,k}^j - \hat{x}_k^j) (\hat{x}_{i,k}^j - \hat{x}_k^j)^T}{N} \quad (14)$$

$$e_k^j = z_k - (h(\hat{x}_k^j, \mu_k) + f_{s,k}^j) \quad (15)$$

$$S_k^i = R + \sum_{i=1}^N \frac{e_{i,k}^j e_{i,k}^{jT}}{N} \quad (16)$$

步骤 3 概率更新。

IMM 利用每个滤波器估计值的似然函数根据式(17)来更新模型概率:

$$\mu_k^j = \frac{L_k^j \sum_{i=1}^M \pi_{ij,k-1} \mu_{k-1}^i}{\sum_{j=1}^M L_k^j \sum_{i=1}^M \pi_{ij,k-1} \mu_{k-1}^i} \quad (17)$$

式中: 似然函数  $L_k^j$  根据各滤波器生成的残差和残差方差进行计算,由于量测噪声服从高斯分布,似然函数为高斯函数,其定义为

$$L_k^j = \frac{1}{\sqrt{|2\pi S_k^j|}} \exp\left(-\frac{e_k^j (S_k^j)^{-1} (e_k^j)^T}{2}\right) \quad (18)$$

在正常工作模式下,正常模型对应的滤波器的模型概率应该逼近于 1,当发生故障时,也就是发生模型切换时,相应滤波器的模型概率应该快速地上升到 1,而其他的模型概率下降到 0。将各滤波器的输出按式(19)~式(21)进行计算,根据模型概率进行加权融合得到 IMM-PF 的估计

结果。

$$\hat{x}_k = \sum_{j=1}^M \mu_k^j \hat{x}_k^j \quad (19)$$

$$P_k = \sum_{j=1}^M \mu_k^j [P_k^j + \Delta \hat{x}_k^j (\Delta \hat{x}_k^j)^T] \quad (20)$$

$$\Delta \hat{x}_k^j = \hat{x}_k^j - \hat{x}_k \quad (21)$$

式中:  $\hat{x}_k$  为 IMM 的状态估计结果;  $P_k$  为估计误差方差。

步骤 4 故障诊断。

利用式(17) 计算得到的模型概率和式(22)、式(23) 决策函数实现故障诊断。当模式失配时, 模型集中没有与当前系统状态匹配的模型, 会导致漏诊。

$$\mu_k^j = \max_i \mu_k^i \quad i, j = 1, 2, \dots, r \quad (22)$$

$$\begin{cases} \frac{\mu_k^j}{\max_{i \neq j} \mu_k^i} \leq \mu_T \Rightarrow H_0: \text{模式失配} \\ \frac{\mu_k^j}{\max_{i \neq j} \mu_k^i} > \mu_T \Rightarrow H_j: \text{模式 } j \end{cases} \quad (23)$$

式中:  $\mu_T$  为根据经验预先设定的诊断阈值, 阈值小则诊断延迟小, 误诊率较高, 阈值大则诊断延迟大, 误诊率较低。

IMM 相较于其他方法有几个显著的优势:

- ①由于同时用几个模型来表示系统的各个工作情况, 相较于单模型的方法, IMM 在系统结构或参数发生变化时也能较好地完成状态估计。
- ②单模型方法需要另外设计故障分离算法, 而 IMM 可以同时完成故障检测和故障分离, 方法设计和实施更容易。
- ③因在每个迭代周期前后引入交互和融合步骤, 相较于一般多模型方法, 如 MMAE, IMM 的模型识别正确率更高, 状态估计结果也更准确。

但 IMM 故障诊断方法存在以下 2 个问题:

- ①当系统处于非模式切换阶段时, 由于标准 IMM 的模型转移概率矩阵是根据先验知识依经验预设的, 并在整个方法迭代过程中保持不变, 难以应对现实应用中的复杂变化。不精确的模型转移概率会影响滤波器之间的交互, 并最终降低系统状态的融合估计精度。
- ②系统处于模式切换阶段时, 模式瞬间发生切换, IMM 通过计算出的模型概率来呈现系统模式的变化, 匹配模型的概率超过阈值, 则完成了对系统模式切换的跟踪。而模型概率的计算由模型转移概率引导, 是一种软切换机制, 所以存在一定的诊断延迟。而在这段延迟内会存在模型竞争, 导致误诊和漏诊, 同时也会降低状态估计的精度。

2.2 模型转移概率自适应修正

针对以上 2 个问题, 本文提出了模型转移概率自适应修正策略和模型概率反转策略。IMM 假设混杂系统的离散模式的随机跳变过程为一阶马尔可夫链, 即模型之间的切换服从:

$$P\{M_k = M_j | M_{k-1} = M_i\} = \pi_{ij} \quad i, j = 1, 2, \dots, r \quad (24)$$

式中:  $M_{k-1}$  和  $M_k$  分别为当前和前一时刻的系统模型;  $\pi_{ij}$  为模型转移概率矩阵。模型转移概率表明了从上一个工作模式切换到另一个模式的概率, 第  $i$  行的对角元素表示维持在上一时刻模式的概率, 该行的非对角元素表示第  $i$  个模型向其他模型转移的概率, 这种模式的依概率切换使得 IMM 利用较少的滤波器就可以获得较好的估计效果并能更好地捕捉系统的模式突变。

系统噪声会影响匹配模型的似然函数, 并影响模型概率的占优程度, 由式(17) 可以看出, 抑制这种影响, 可以通过修正模型转移概率  $\pi_{ij}$ 。在非模式切换阶段, 对模型转移概率修正的主要目标是在系统模式稳定时保持匹配模型的模型概率占优。

IMM 的后验信息模型概率反映了各模型与实际系统的匹配程度, 它的变化也能很好地反应模型占优程度的变化, 因此考虑利用其设计修正函数在线自适应地修正模型转移概率。

$$\varphi_k^j = [\exp(\mu_k^j - \mu_{k-1}^j)]^\gamma \quad (25)$$

$$\pi'_{ij, k} = \varphi_k^j \pi_{ij, k-1} \quad (26)$$

$$\pi_{ij, k} = \frac{\pi'_{ij, k}}{\sum_{j=1}^M \pi'_{ij, k}} \quad (27)$$

式中:  $\varphi_k^j$  为修正函数;  $\gamma$  为设置的修正速率。令  $\mu_k^j - \mu_{k-1}^j = \Delta\mu$ , 可见当模型概率上升时,  $0 < \Delta\mu < 1$ ,  $\varphi_k^j > 1$ , 则修正后相应模型的模型转移概率上升, 也就是其他模型切换到该模型的概率上升。相反的, 若模型概率下降,  $-1 < \Delta\mu < 0$ ,  $\varphi_k^j < 1$ , 则修正后该模型的模型转移概率下降, 其他模型切换到该模型的概率减少。可以看出, 这种修正可以提高匹配模型的占优的比重, 使其在非模式切换阶段时保持匹配模型的模型概率稳定并趋近 1, 从而最终提高状态估计的精确度。

2.3 模型概率的反转策略

在模式切换阶段对模型概率修正的主要目标是保证模型概率在系统模式发生变化时快速地切换。IMM 软切换机制会导致诊断延迟, 而如果继续使用非模式切换阶段的修正策略, 会使模型转

移概率积累许多历史信息,即转移向某一模型的概率偏大,导致更长的诊断延迟。模型的似然函数也能反应模型与系统的匹配程度,且当模式发生变化时也会发生相应变化,因此采用模型的似然函数值之比  $\lambda_{lik}$  来切换修正方式,其计算公式为

$$\lambda_{lik} = \frac{L_k^j}{L_k^i} \quad i, j = 1, 2, \dots, r \quad (28)$$

式中:  $L_k^j = \max_h L_k^h, L_k^i = \max_{h \neq j} L_k^h$ 。当发生模式切换,不再使用 2.2 节中的修正函数对模型转移概率进行修正,而改为修正后验模型概率。当似然比小于所设置阈值  $thr$ ,说明模型似然值最大和次大的模型很接近,有模型切换的趋势,因此本文采取模型概率反转策略,将似然值次大的后验模型概率赋值到接近 1,而将其他模型赋值到接近 0,并将非模式切换阶段修正的模型转移概率重置为初始矩阵。这样修正后就排除了过去积累的修正信息,而只考虑当前模式的变化,从而提高模型概率的切换速度。基于上述 2 种策略进行修正的 MIMM-PF( Modified IMM-PF) 故障诊断方法的流程图如图 2 所示。

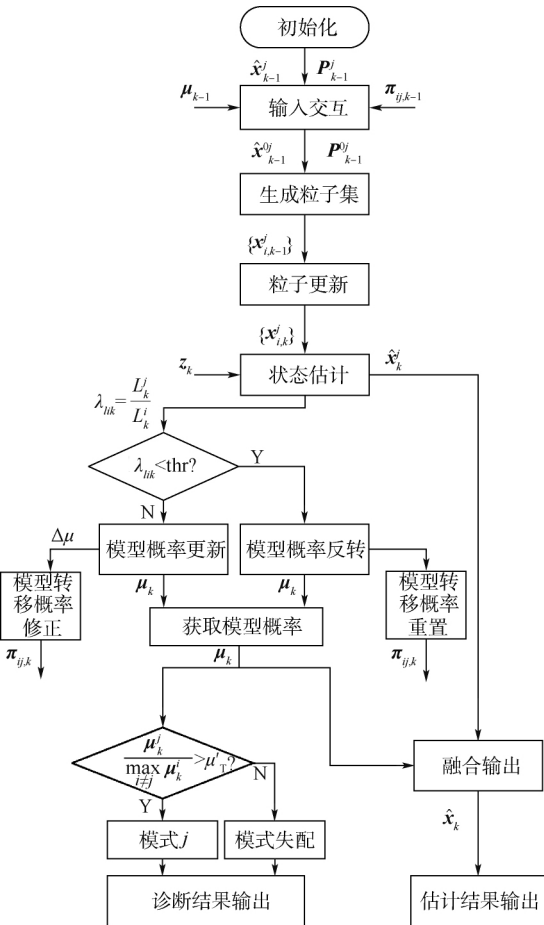


图 2 MIMM-PF 故障诊断方法流程图

Fig. 2 Flowchart of MIMM-PF fault diagnosis method

### 3 实验与分析

#### 3.1 故障影响分析

建立如图 3 所示的仿真实验框架,在 MATLAB/Simulation 平台上对第 2 节所描述的风机基准模型进行仿真,风机的详细参数包括所采用风速参见文献 [16]。图中:  $\beta_{mes}$  和  $\hat{\beta}$  分别为桨距角的量测值和估计值。

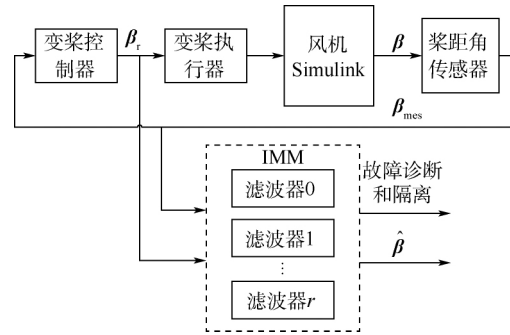


图 3 仿真实验框架

Fig. 3 Framework of simulation experiment

所使用的风速覆盖了风机的 2 个工况: 变速工况( 风速 3 ~ 15 m/s) 和变桨工况( 风速 15 ~ 25 m/s)。由于变桨系统只有在高风速下的变桨工况才会进行变桨动作,本文选取变桨工况中的 600 个采样点进行仿真实验。选取 3 个传感器故障模型与正常模型构成模型集,其故障幅值与注入时间设置如式( 29) 所示:

$$\left. \begin{aligned} \text{故障模型 1 正常} & \quad t \leq 100\Delta T \quad t > 600\Delta T \\ \text{故障模型 2 } \beta_{bias} = -2^\circ & \quad 300\Delta T < t \leq 400\Delta T \\ \text{故障模型 3 } k_{gain} = 0.5 & \quad 100\Delta T < t \leq 200\Delta T \\ \text{故障模型 4 } \beta_{fixed} = 3^\circ & \quad 500\Delta T < t \leq 600\Delta T \end{aligned} \right\} \quad (29)$$

式中:  $\Delta T$  为采样间隔。

通过如图 4 所示的正常叶片与故障叶片的仿真结果对比可以看到故障对变桨系统的影响。 $t$  在  $100\Delta T \sim 200\Delta T$  范围内时,模式由正常到恒增益故障的切换瞬间故障叶片的传感器输出变为正常叶片的一半,而由于闭环系统中的 PI 控制器对故障具有补偿作用,变桨系统的输入值发生了反向的变化,导致桨距角也向相同的方向变化,从而传感器的输出慢慢变为实际桨距角的一半。 $t$  在  $200\Delta T \sim 300\Delta T$  范围内时,模式由恒增益故障到正常的切换瞬间,由于前面传感器故障的影响,桨距角还处在反向异常的值,所以传感器输出有一个反向的跳变,随着故障消失,桨距角状态值和观测值也渐渐地恢复到和正常叶片一样。相同地,




图 4 故障对输出、输入和状态的影响

Fig. 4 Fault impact on output, input and state

由于控制器的补偿作用,  $t$  在  $300\Delta T \sim 400\Delta T$  范围内时, 桨距角传感器发生  $-2^\circ$  的偏置故障,  $t$  在  $500\Delta T \sim 600\Delta T$  范围内时, 发生卡死故障时, 系统的输入和状态都发生了反相的变化。由于变桨系统传感器故障导致的这种复杂变化, 传统基于单滤波器的故障诊断方法很难满足性能上的需求。

### 3.2 方法验证

为了验证应用 IMM-PF 对风机变桨系统传感器多故障的有效性, 针对式 (29) 所建立的模型集, 分别设计 4 个相应的粒子滤波器, 采用 IMM-PF 故障诊断方法, 对从图 3 所示仿真系统得到的输入输出数据进行在线的自适应估计, 通过模型概率的计算得到当前时刻与实际系统最匹配的模型, 并进行融合输出, 从而得到变桨系统的状态估计和诊断结果, 并与 MMAE-PF 进行了对比。实验参数设置如下: 仿真时间为 6 s, 采样周期为 0.01 s, 粒子滤波器粒子数为 50, 过程噪声和量测噪声分别为  $w \sim \Gamma(0.1, 0.1)$ ,  $v \sim N(0, 0.001)$ , 桨距角初始值  $x_0 = 10$ , 诊断阈值  $\mu_T$  设置为 9.9, 初始模型概率为  $\mu_0 = (0.7, 0.1, 0.1, 0.1)^T$ , 初始模型转移概率设置为

$$\pi_{ij} = \begin{bmatrix} 0.99 & 0.0034 & 0.0034 & 0.0032 \\ 0.0032 & 0.99 & 0.0034 & 0.0034 \\ 0.0032 & 0.0034 & 0.99 & 0.0034 \\ 0.0032 & 0.0034 & 0.0034 & 0.99 \end{bmatrix}$$

实验设备配置为 Inter Core i5-8520@1.6 GHz, 内存 8 GB, 操作系统 Windows10。

使用标准 IMM-PF 故障诊断方法得到如图 5 所示的诊断和状态估计结果, 图中模型序号为 0 表示识别结果与 4 种模型都不匹配的漏诊情况。从图 5 (a) 可以看到, MMAE-PF 方法出现了较多的漏报, 而标准 IMM-PF 除了在模式发生切换时存在一定的时间延迟, 整个过程有较少的漏报, 诊断结果整体上与预设的模式序列相吻合。从图 5 (b) 可以看出, MMAE-PF 的估计偏离实际桨距角的程度较大, 而 IMM-PF 大部分区间内的桨距角估计较为准确, 误差较小, 只是  $t$  在  $500\Delta T \sim 600\Delta T$  范围内时, 发生传感器卡死, 桨距角估计都发生了振荡。这是由于输入值在变化, 而滤波器无法获得相应的输出值的更新。从结果可以看出无论是故障诊断还是状态估计, IMM-PF 总体上都可以满足需求。

为了验证所提出的自适应修正 IMM-PF (MIMM-PF) 方法的性能, 本文将其与标准 IMM-PF 在 3.1 节所建立的故障诊断仿真框架下进行性能对比实验。方法修正前后的模型概率变化对比如图 6 所示, 图中修正 1~修正 4 为采用修正方法后的模型 1、2、3、4 的曲线。可以看到, 在  $t = 200\Delta T$  处模型切换后的模型概率发生了反转, 模

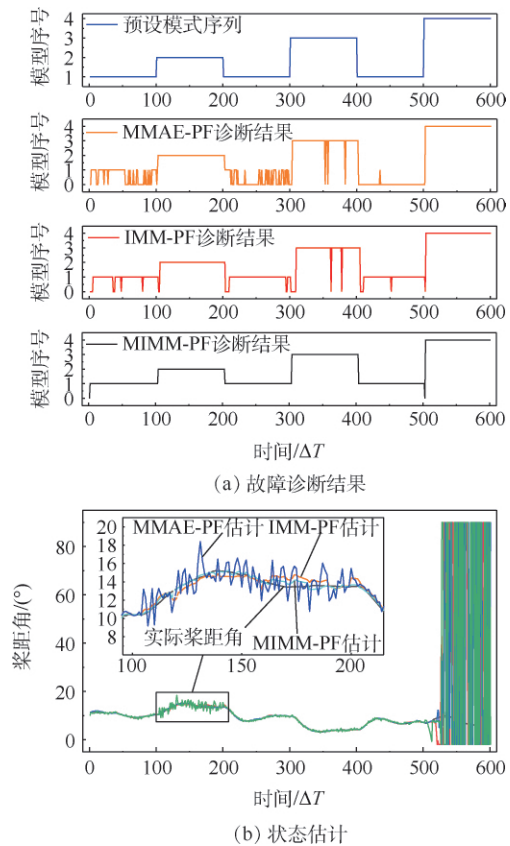


图 5 故障诊断结果和状态估计

Fig. 5 Fault diagnosis results and state estimation




图6 模型概率变化曲线

Fig. 6 Model probability variation curves

型0的模型概率上升到接近1,其他模型的概率下降到接近0。而修正后相较标准 IMM-PF 方法的模型概率切换速度更快,切换后的模型概率也更接近于1。由于诊断和融合估计都要使用模型概率,这样的效果有利于提高方法诊断的速度、准确度和状态估计的精度。从图5(a)修正后的诊断结果可以看出,正确识别故障的数量明显增加,且在模型切换时的延迟和模型失配也得到了减少;从图5(b)的修正后的状态估计结果可以看出,桨距角也能更好地逼近真实值。

为综合评价这两种方法的性能,本文选取了以下3个指标:正确诊断(CDID),也就是诊断结果与实际模式匹配的个数,诊断延迟情况下从发生模式切换到给出正确诊断结果的时间间隔(Delay)以及融合估计的均方根误差(RMSE),其定义如下:

$$RMSE_l = \sqrt{\frac{1}{N} \sum_{n=1}^N (x_{l,n} - \hat{x}_{l,n})^2} \quad (30)$$

式中: $x_{l,n}$ 为第 $l$ 次迭代第 $n$ 个采样点的实际值; $\hat{x}_{l,n}$ 为第 $l$ 次迭代第 $n$ 个采样点的 IMM 估计值。由于卡死阶段无法有效估计状态,本文选取前500个采样点计算均方根误差。MIMM-PF 的参数 thr 通过实验选取为 0.5,  $\gamma$  选取 2。模型切换时将模型概率次大的模型概率赋值为 0.999,其他模型则置为 0.001/3。运行 50 次蒙特卡罗实验,得到的性能指标平均值统计结果如表 2 所示。

表2 MIMM-PF 与标准 IMM-PF 性能对比

Table 2 Performance comparison between MIMM-PF and standard IMM-PF

指标	IMM-PF	MIMM-PF
CDID	564.54 (94.09%)	582.76 (97.13%)
Delay	6.36 $\Delta T$	3.6833 $\Delta T$
RMSE	1.2438	0.5434

注:( ) 内为 CDID 的百分比形式。

从表2中的数据可以看出,修正后的故障诊断方法提高了 18.22 个正确诊断数,提升了近 3%,减少了 2.6767 个采样间隔的延迟时间,降低了 56.31% 的估计误差。此统计结果表明本文所提出的修正方法对基于标准 IMM-PF 的故障诊断方法从准确性、速度和状态估计精度都得到了较好的提升。为进一步增加方法对于强噪声的鲁棒性,下一步的工作将对 IMM-PF 中的粒子滤波进行分析和改进,如文献[19]根据噪声和误差进行状态转移密度方差的自适应调整,以增加粒子滤波对强噪声的抗干扰能力。

## 4 结论

1) 建立了风机变桨系统传感器的多种故障的故障模型,将 IMM 与 PF 结合,在所建立的模型集上实现了自适应估计、故障检测与分离。

2) 在此基础上,为 IMM 方法设计了新的在线自适应修正方法。在非模型切换阶段,利用模型概率梯度设计修正函数自适应地修正模型转移概率。

3) 利用模型似然函数比检测模式切换,并在模式切换阶段使用反转策略直接修正模型概率。

4) 在风机仿真系统上应用所设计的 MIMM-PF 故障诊断方法,可以实现预期的效果,并且诊断准确性、速度和状态估计精度相较标准方法都得到了较好的提高。

## 参考文献 (References)

- [1] 曾军,陈艳峰,杨苹,等.大型风力发电机组故障诊断综述[J].电网技术,2018,42(3):849-860.  
ZENG J, CHEN Y F, YANG P, et al. Review of fault diagnosis methods of large-scale wind turbines [J]. Power System Technology, 2018, 42(3): 849-860 (in Chinese).
- [2] 吴定会,刘稳,张秀丽.基于改进多胞形观测器的桨距执行器故障诊断[J].信息与控制,2018,47(5):26-32.  
WU D H, LIU W, ZHANG X L. Fault diagnosis of pitch actuator using improved polytope observer [J]. Information and Control, 2018, 47(5): 26-32 (in Chinese).
- [3] CHEN L, SHI F, PATTON R. Active FTC for hydraulic pitch system for an off-shore wind turbine [C] // Conference on Control and Fault-Tolerant Systems (SysTol). Piscataway: IEEE Press, 2013: 510-515.
- [4] 吴定会,翟艳杰,李意扬,等.基于辨识算法的风力机桨距执行器故障诊断[J].控制工程,2016,23(6):795-799.  
WU D H, ZHAI Y J, LI Y Y, et al. Fault diagnosis for pitch actuators of wind turbines based on identification algorithm [J]. Control Engineering of China, 2016, 23(6): 795-799 (in Chinese).
- [5] VASQUEZ S, KINNAERT M, PINTELON R. Active fault diag-

- nosis on a hydraulic pitch system based on frequency-domain identification [J]. IEEE Transactions on Control Systems Technology 2019, 27(2): 663-678.
- [6] 赵洪山, 连莎莎, 邵玲. 基于模型的风电机组变桨距系统故障检测[J]. 电网技术, 2015, 39(2): 440-444.  
ZHAO H S, LIAN S S, SHAO L. A model-based fault detection for variable-pitch system of wind turbines [J]. Power System Technology 2015, 39(2): 440-444 (in Chinese).
- [7] WU D, ZHAI Y, GAO W, et al. Multi-innovation observer based fault detection for pitch system of wind turbines [C] // 2015 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER). Piscataway: IEEE Press, 2015: 677-680.
- [8] ZHU J S, MA K C, HAJIZADEH A. Fault detection and isolation for wind turbine electric pitch system [C] // 2017 IEEE 12th International Conference on Power Electronics and Drive Systems (PEDS). Piscataway: IEEE Press, 2017: 618-623.
- [9] ZHANG Y, LI X R. Detection and diagnosis of sensor and actuator failures using IMM estimator [J]. IEEE Transactions on Aerospace and Electronic Systems, 1998, 34(4): 1293-1313.
- [10] 周卫东, 孙天, 储敏, 等. 交互式多模型粒子滤波优化重采样算法[J]. 北京航空航天大学学报, 2017, 43(5): 865-871.  
ZHOU W D, SUN T, CHU M, et al. Interacting multiple model particle filter optimization resampling algorithm [J]. Journal of Beijing University of Aeronautics and Astronautics, 2017, 43(5): 865-871 (in Chinese).
- [11] GADSDEN S A, SONG Y, HABIBI S R. Novel model-based estimators for the purposes of fault detection and diagnosis [J]. IEEE/ASME Transactions on Mechatronics, 2013, 18(4): 1237-1249.
- [12] 顾欣欣. 基于多模型的高速列车牵引系统多故障分离方法研究[D]. 南京: 南京航空航天大学, 2016: 39-55.  
GU X X. Multiple-model based fault detection and isolation for electric traction system of railway high-speed [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2016: 39-55 (in Chinese).
- [13] 邢璐璐. 基于 IMM 的车辆垂向减振器故障诊断方法研究[J]. 中国铁道科学, 2018, 39(6): 121-127.  
XING L L. Fault diagnosis method of vehicle vertical damper based on IMM [J]. China Railway Science, 2018, 39(6): 121-127 (in Chinese).
- [14] 郭志, 董春云, 蔡远利, 等. 时变转移概率 IMM-SRCKF 机动目标跟踪算法[J]. 系统工程与电子技术, 2015, 37(1): 24-30.  
GUO Z, DONG C Y, CAI Y L, et al. Time-varying transition probability based IMM-SRCKF algorithm for maneuvering target tracking [J]. Systems Engineering and Electronics, 2015, 37(1): 24-30 (in Chinese).
- [15] 许登荣, 程水英, 包守亮. 自适应转移概率交互式多模型跟踪算法[J]. 电子学报, 2017, 45(9): 2113-2120.  
XU D R, CHENG S Y, BAO S L. Interacting multiple model algorithm based on adaptive transition probability [J]. Acta Electronica Sinica, 2017, 45(9): 2113-2120 (in Chinese).
- [16] ODGAARD P F, STOUSTRUP J, KINNAERT M. Fault-tolerant control of wind turbines: A benchmark model [J]. IEEE Transactions on Control Systems Technology, 2013, 21(4): 1168-1182.
- [17] 曹洁, 杜永红, 王进花. 自适应蝙蝠算法优化 PF 的风力机变桨距系统故障诊断方法[J]. 计算机应用与软件, 2018, 35(5): 78-84.  
CAO J, DU Y H, WANG J H. Fault diagnosis method for pitch system of wind turbines based on adaptive bat algorithm optimized PF [J]. Computer Applications and Software, 2018, 35(5): 78-84 (in Chinese).
- [18] 刘悄然, 杨训. 基于改进的交互式多模型粒子滤波算法[J]. 西北工业大学学报, 2018, 36(1): 169-175.  
LIU Q R, YANG X. Improved interacting multiple model particle filter algorithm [J]. Journal of Northwestern Polytechnical University, 2018, 36(1): 169-175 (in Chinese).
- [19] 王进花, 曹洁, 李伟, 等. 强噪声环境下自适应 CRPF 故障诊断方法[J]. 北京航空航天大学学报, 2018, 44(5): 923-930.  
WANG J H, CAO J, LI W, et al. An adaptive CRPF fault diagnosis method under strong noise condition [J]. Journal of Beijing University of Aeronautics and Astronautics, 2018, 44(5): 923-930 (in Chinese).

#### 作者简介:

王进花 女, 博士, 副教授。主要研究方向: 故障诊断、非线性滤波方法及应用。

朱恩昌 男, 硕士研究生。主要研究方向: 故障诊断、智能信息处理。



## Fault diagnosis method for wind turbine pitch system based on modified IMM

WANG Jinhua<sup>1 2 3 \*</sup>, ZHU Enchang<sup>1 2</sup>, CAO Jie<sup>1 2</sup>, YU Ping<sup>1 2 3</sup>

(1. College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China;

2. Gansu Provincial Key Laboratory of Industrial Process Control, Lanzhou 730050, China;

3. National Experimental Teaching Demonstration Center of Electrical and Control Engineering,  
Lanzhou University of Technology, Lanzhou 730050, China)

**Abstract:** Aimed at the diagnostic accuracy reduction, speed drop and estimation accuracy loss caused by the fixed model transition probability of Interactive Multi-Model (IMM) fault diagnosis method, this paper proposes a fault diagnosis method based on model transition probability and model probability modification, which is combined with the Particle Filter (PF) to achieve multi-fault diagnosis of wind turbine pitch sensor. In the non-mode-switching phase, the posterior model probability gradient information is used to design the modification function of the model transition probability to suppress the influence of noise on the accuracy of IMM estimation. In the mode-switching phase, the model probability inversion strategy is used to quickly switch models to compensate for diagnostic delay and error diagnosis caused by model soft handoff. The simulation results show that the fault diagnosis accuracy, model switching speed and state estimation accuracy of the proposed method are improved.

**Keywords:** wind turbine; pitch system; fault diagnosis; Interactive Multi-Model (IMM); Particle Filter (PF); model transition probability

**Received:** 2019-09-26; **Accepted:** 2019-11-17; **Published online:** 2019-11-27 13:08

**URL:** [kns.cnki.net/kcms/detail/11.2625.V.20191127.1150.001.html](http://kns.cnki.net/kcms/detail/11.2625.V.20191127.1150.001.html)

**Foundation items:** National Natural Science Foundation of China (61763028); Natural Science Foundation of Gansu Province, China (1506RJZA105)

\* **Corresponding author.** E-mail: wjh0615@lut.edu.cn