

基于 MISG 算法的风力发电机液压变桨系统故障诊断^{*}

黄文韬，文传博
(上海电机学院 电气学院, 上海 201306)

摘要：针对受状态延时影响的风机变桨系统故障诊断, 提出了一种基于多新息随机梯度(MISG)的故障诊断方法。该方法将复杂系统转化为状态空间模型, 并建立系统辨识模型。将新息标量扩展成新息向量改善算法精度, 利用系统发生故障引起参数改变的特征, 算法对风机状态延时变桨系统完成参数估计, 将系统故障诊断问题转换为系统辨识问题。仿真所得结果验证该方法可以达到诊断风机状态延时变桨系统故障的目的。

关键词：风力发电机；状态延时；变桨系统；故障诊断；系统多新息辨识

中图分类号：TM 315 文献标志码：A 文章编号：1673-6540(2018)11-0110-06

Fault Diagnosis of Wind Turbine Hydraulic Pitch System Based on Multi-Innovation Stochastic Gradient Algorithm^{*}

HUANG Wentao, WEN Chuanbo

(School of Electrical Engineering, Shanghai Dianji University, Shanghai 201306, China)

Abstract: Aiming at fault diagnosis of wind turbine pitch system affected by state delay, a new fault diagnosis method based on multi-innovation stochastic gradient algorithm was proposed. This complex system was modeled as a state space model, and the system identification model was established. The algorithm extended the innovation scalar into innovation vector to improve the accuracy. The changes of parameters could be caused by the fault of the system, and the algorithm was used to estimate the parameters of wind turbine pitch system with state delay. The fault diagnosis issue was transformed into identification problem. Simulation results showed that this method could achieve the purpose of diagnosing the fault of wind turbine pitch system with state delay.

Key words: wind turbine; state delay; pitch system; fault diagnosis; system multi-innovation identification

0 引言

随着传统化石能源的告急和全球环境的恶化, 风、光作为新型可再生能源为代表的发电技术迅速兴起^[1]。全球的风能约 2.74×10^9 MW, 其中可利用风能为 2×10^9 MW, 比地球上可开发利用的水能总量还要大 10 倍, 风电装机容量正稳步增加。风电场所处环境恶劣, 在保证大容量高效发电的同时, 也为设备的后期维护带来了挑战, 变桨

系统故障频发尤为明显^[2]。变桨系统改变桨距角以输出恒定功率, 是风电机组的重要组成部分^[3], 同时也是导致风机故障频发的重要部件之一^[4]。变桨系统故障给电网正常运行带来巨大的困难和挑战。因而快速准确地诊断变桨系统的故障是确保系统稳定运行的必要条件^[5]。

近年来, 许多研究人员对风机及变桨系统故障诊断颇有研究。基于数据的故障诊断方法在风机及液压系统中已有些研究成果。文献[6]采用

* 基金项目：国家自然科学基金项目(61374136, 61473159); 上海市人才发展资金项目(201511)

作者简介：黄文韬(1993—), 男, 硕士研究生, 研究方向为故障诊断。

文传博(1981—), 男, 博士, 副教授, 硕士生导师, 研究方向为风电设备故障诊断、目标跟踪与状态估计。

基于人工神经网络的方法检测液压执行器液压泄漏故障。文献[7]利用基于 RS-SVM(粗糙集理论-支持向量机)的数据融合方法诊断液压系统故障。文献[8]利用风力发电机组监测的历史数据和故障数据信息,分别建立变桨系统正常与故障时的数据样本,基于 Relief 方法对风机部件的故障特征参数进行挖掘。文献[9]提出一种有效的预处理监控与数据采集(Supervisory Control and Data Acquisition, SCADA)系统原始数据的方法并提取出足以反映故障信息的特征值,然后,基于分析 SCADA 数据间的相关性对风机故障诊断进行研究。文献[10]则提出基于主成分分析与统计假设检验的方法对风电机组故障检测。针对风机及变桨系统故障研究,基于模型的故障诊断方法具有更好的故障检测性能,设计方法灵活,鲁棒性较强。文献[11]运用基于观测器的多新息辨识算法对风机变桨系统进行故障诊断,系统辨识通过系统的输入输出数据能够估计系统参数,将故障诊断转化为参数估计问题,实现系统状态和参数的交互估计^[12]。

但目前的研究并没有考虑实际风机系统存在的状态延时问题。风力发电机在运行期间状态改变缓慢,必然存在状态延时。风机存在状态延时影响控制性能,对系统实时性和可靠性产生一定影响,同时影响系统的动态性能^[13]。状态延时对系统动态性能的不确定影响,给系统故障诊断带来了本质上的困难,其对于故障诊断的要求更高,诊断过程的复杂性也有所提高。故障诊断需要寻求精度高、收敛速度快的算法,所以研究受状态延时影响的风机变桨系统故障诊断具有重要的理论价值和实际意义。

本文考虑状态延时的影响,对风机液压变桨系统重新建模,经过转化得到辨识模型,提出一种基于多新息随机梯度(Multi-Innovation Stochastic Gradient, MISG)的故障诊断算法估计状态延时变桨系统参数和状态。然后通过跟踪参数的变化和大小,诊断故障的发生并加以识别。最后,仿真验证该方法的可行性和合理性。

1 模型描述

1.1 风机系统模型

风机模型包含:气动系统模型、变桨系统模

型、传动系统模型和功率子系统模型(变流器及发动机)。其模型结构如图 1 所示。

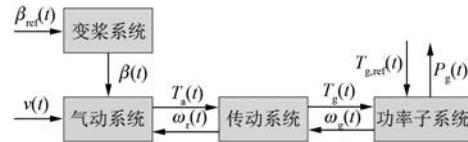


图 1 风机系统结构

叶片在风力推动作用下,桨距角发生变化,转子捕捉风能,使风机气动模型产生气动转矩,随后气动转矩传入传动系统。在传动系统中,转子在齿轮箱的作用下使发动机获得所需转速。发动机通过变流器将其产生的电能传输到电网。桨距角输出参考值以及发动机输出转矩参考值控制叶片桨距角(由变桨系统控制)及发动机转矩(由变流器控制)。

1.2 液压变桨系统延时动态模型

变桨系统由 3 个完全相同的液压变桨执行器构成,通过控制桨叶转动改变桨距角,如图 2 所示。

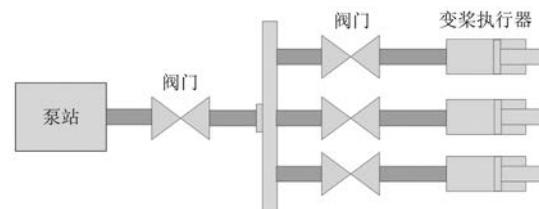


图 2 变桨系统示意图

液压变桨执行器可以建模为桨距角 $\beta(t)$ 和桨距角参考值 $\beta_{ref}(t)$ 之间的传递函数。 $\beta(t)$ 是变桨系统输出, $\beta_{ref}(t)$ 是风机控制器给出的设定值,变桨执行器的二阶传递函数模型如下^[14]:

$$\frac{\beta(s)}{\beta_{ref}(s)} = \frac{\omega_n^2}{s^2 + 2\zeta\omega_n s + \omega_n^2} \quad (1)$$

式中: ω_n ——自然频率;

ζ ——阻尼系数。

其动态模型为

$$\ddot{\beta}(t) = -2\zeta\omega_n\dot{\beta}(t) - \omega_n^2\beta(t) + \omega_n^2\beta_{ref}(t) \quad (2)$$

考虑状态延时的影响,风机液压变桨系统动态模型为

$$\ddot{\beta}(t) = -2\zeta\omega_n\dot{\beta}(t) - \omega_n^2\beta(t) + \omega_n^2\beta_{ref}(t) + b_{11}\dot{\beta}(t-d) + b_{12}\beta(t-d) \quad (3)$$

式中: d ——变桨执行器的时间延迟;

b_{11}, b_{12} ——常数。

1.3 故障模型

液压泄漏、泵磨损、液油空气含量过高(分别用a、b、c表示3种故障情况)是液压变桨执行器故障的主要类型。此3种故障会改变系统内特征参数 ω_n, ζ ,导致系统动态特性变差,随之使执行器反应速度变慢。当故障发生时,变桨执行器的自然频率和阻尼系数将分别从正常值变成故障时对应的特征参数值。

故障时,变桨执行器闭环特征参数可表达为

$$\omega_{n,r}(t) = [1 - \eta_r(t)]\omega_{n,0} + \eta_r(t)\omega_{n,r} \quad (4)$$

$$\zeta_r(t) = [1 - \eta_r(t)]\zeta_0 + \eta_r(t)\zeta_r \quad (5)$$

其中: $r=a,b,c$ 分别代表3种故障; $\eta_r(t)$ 为故障信号,且 $\eta_r(t)=0$ 或1。由表达式可看出,当故障信号为0时,系统无故障;而当其为1时,则故障发生。那么可得变桨系统故障模型为

$$\begin{aligned} \ddot{\beta}(t) = & -2\zeta_r\omega_{n,r}\dot{\beta}(t) - \omega_{n,r}^2\beta(t) + \omega_{n,r}^2\beta_{ref}(t) + \\ & b_{11}\dot{\beta}(t-d) + b_{12}\beta(t-d) \end{aligned} \quad (6)$$

2 基于MISG的故障诊断算法

基于前文建立的动态模型,完成对风机变桨系统的故障诊断。先将针对状态延时系统建立的模型进行转化,然后将MISG算法应用于辨识模型。系统输入变桨角参考值 $\beta_{ref}(t)$ 和实际变桨角 $\beta(t)$,估计出参数 $\omega_n(t)$ 和 $\zeta(t)$ 。

2.1 状态空间方程

对于上述的系统故障模型式(6),通过选取状态量 $x(t) = [\dot{\beta}(t) \quad \beta(t)]^T$ 和输出量 $y(t) = \beta(t)$,可得其连续状态空间方程为

$$\begin{cases} \dot{x}(t) = Ax(t) + Bu(t) + B_1x(t-d) \\ y(t) = Cx(t) + v(t) \end{cases} \quad (7)$$

即:

$$\begin{cases} \begin{bmatrix} \ddot{\beta}(t) \\ \dot{\beta}(t) \end{bmatrix} = A \begin{bmatrix} \dot{\beta}(t) \\ \beta(t) \end{bmatrix} + B\beta_{ref}(t) + B_1 \begin{bmatrix} \dot{\beta}(t-d) \\ \beta(t-d) \end{bmatrix} \\ y(t) = C \begin{bmatrix} \dot{\beta}(t) \\ \beta(t) \end{bmatrix} + v(t) \end{cases} \quad (8)$$

$$\text{其中: } A = \begin{bmatrix} -2\zeta_r(t)\omega_{n,r}(t) & -\omega_{n,r}^2(t) \\ 1 & 0 \end{bmatrix}, B =$$

$$\begin{bmatrix} \omega_{n,r}^2(t) \\ 0 \end{bmatrix}, C = [0 \quad 1], B_1 = \begin{bmatrix} b_{11} & b_{12} \\ 0 & 0 \end{bmatrix}.$$

式中: $v(t)$ ——噪声。

2.2 离散化及系统可辨识分析

阶跃响应不变法是常用的离散化方法,能够保证离散系统输出等于连续系统在采样点的输出值^[15]。运用该方法离散处理状态空间方程式(8),取 T_0 为采样周期:

$$\begin{cases} \begin{bmatrix} \dot{\beta}(k+1) \\ \beta(k+1) \end{bmatrix} = \bar{A} \begin{bmatrix} \dot{\beta}(k) \\ \beta(k) \end{bmatrix} + \bar{B}\beta_{ref}(k) + \bar{B}_1 \begin{bmatrix} \dot{\beta}(k-d) \\ \beta(k-d) \end{bmatrix} \\ y(k) = \bar{C} \begin{bmatrix} \dot{\beta}(k) \\ \beta(k) \end{bmatrix} + v(k) \end{cases} \quad (9)$$

$$\text{其中: } \bar{A} = \begin{bmatrix} 1 - 2\zeta_r(k)\omega_{n,r}(k)T_0 & -\omega_{n,r}^2(k)T_0 \\ T_0 & 1 \end{bmatrix},$$

$$\bar{B} = \begin{bmatrix} \omega_{n,r}^2(k)T_0 \\ 0 \end{bmatrix}, \bar{C} = [0 \quad 1], \bar{B}_1 = \begin{bmatrix} b_{11} & b_{12} \\ 0 & 0 \end{bmatrix}.$$

由于系统辨识的需要,首先判别系统的可辨识性。系统式(9)能观矩阵与能控矩阵分别为

$$Q_o = \begin{bmatrix} \bar{C} \\ \bar{C}A \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ T_0 & 1 \end{bmatrix},$$

$$Q_c = [\bar{B} \quad \bar{A}\bar{B}] =$$

$$\begin{cases} \omega_{n,r}^2(k)T_0 & [1 - 2\zeta_r(k)\omega_{n,r}(k)]\omega_{n,r}^2(k)T_0^2(k) \\ 0 & \omega_{n,r}^2(k)T_0 \end{cases}.$$

由于 $\text{Rank } Q_o = 2$,能观矩阵满秩,因而系统能观。同理, $\text{Rank } Q_c = 2$,可知该系统可控,即该系统可辨识。

2.3 辨识模型

令 $\tilde{x}(k) = Q \begin{bmatrix} \dot{\beta}(k) & \beta(k) \end{bmatrix}^T = [\tilde{x}_1(k) \quad \tilde{x}_2(k)]^T$,可变换系统方程为

$$\begin{cases} \tilde{x}(k+1) = \tilde{A}x(k) + \tilde{B}\beta_{ref}(k) + \tilde{B}_1\tilde{x}(k-d) \\ y(k) = \tilde{C}\tilde{x}(k) + v(k) \end{cases} \quad (10)$$

$$\text{其中: } Q = \begin{bmatrix} 1 & 2\zeta_r(k)\omega_{n,r}(k)T_0 - 2 \\ 0 & 1 \end{bmatrix},$$

$$\tilde{A} = Q\bar{A}Q^{-1} =$$

$$\begin{bmatrix} 0 & -(1 - 2\zeta_r(k)\omega_{n,r}(k)T_0 + \omega_{n,r}^2(k)T_0^2) \\ 1 & -(2\zeta_r(k)\omega_{n,r}(k)T_0 - 2) \end{bmatrix},$$

$$\tilde{B} = Q\bar{B} = \begin{bmatrix} \omega_{n,r}^2(k)T_0^2 \\ 0 \end{bmatrix},$$

$$\tilde{\mathbf{C}} = \bar{\mathbf{C}}\mathbf{Q}^{-1} = [0 \ 1], \tilde{\mathbf{B}}_1 = \begin{bmatrix} b_{11} & b_{12} \\ 0 & 0 \end{bmatrix}.$$

定义新状态向量 $x(k) = [x_1(k) \ x_2(k)]^T = \tilde{\mathbf{P}}\tilde{x}(k) = [\tilde{x}_2(k) \ \tilde{x}_1(k)]^T$, 即 $x_1 = \tilde{x}_2 = \beta(k), x_2 = \tilde{x}_1 = \dot{\beta}(k) + [2\zeta_r(k)\omega_{n,r}(k)T_0 - 2]\beta(k), u(k) = \beta_{ref}(k)$ 为输入, $y(k)$ 为输出, 则可得新状态空间系统为

$$\begin{cases} \tilde{x}(k+1) = \tilde{\mathbf{A}}x(k) + \tilde{\mathbf{B}}\beta_{ref}(k) + \tilde{\mathbf{B}}_1\tilde{x}(t-d) \\ y(k) = \tilde{\mathbf{C}}\tilde{x}(k) + v(k) \end{cases} \quad (11)$$

记

$$\begin{cases} a_1 = 2\zeta_r(k)\omega_{n,r}(k)T_0 - 2 \\ a_2 = 1 - 2\zeta_r(k)\omega_{n,r}(k)T_0 + \omega_{n,r}^2(k)T_0^2 \\ b_2 = \omega_{n,r}^2(k)T_0^2 \end{cases} \quad (12)$$

其中: $\mathbf{P} = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}, \mathbf{A} = \mathbf{P}\tilde{\mathbf{A}}\mathbf{P}^{-1} = \begin{bmatrix} -a_1 & 1 \\ -a_2 & 0 \end{bmatrix}, \mathbf{B} = \mathbf{P}\tilde{\mathbf{B}} = \begin{bmatrix} 0 \\ b_2 \end{bmatrix}, \mathbf{C} = \tilde{\mathbf{C}}\mathbf{Q}^{-1} = [0 \ 1], \tilde{\mathbf{B}}_1 = \begin{bmatrix} 0 & 0 \\ b_{11} & b_{12} \end{bmatrix}.$

综合上述式可得:

$$\begin{cases} x(k+1) = \begin{bmatrix} -a_1 & 1 \\ -a_2 & 0 \end{bmatrix}x(k) + \begin{bmatrix} 0 \\ b_2 \end{bmatrix}u(k) + \begin{bmatrix} 0 & 0 \\ b_{11} & b_{12} \end{bmatrix}x(t-d) \\ y(k) = [1 \ 0]x(k) + v(k) \end{cases} \quad (13)$$

由式(13)可得:

$$x_1(k+1) = -a_1x_1(k) + x_2(k) + b_1u(k) + b_{11}x_1(k-d) \quad (14)$$

$$x_2(k+1) = -a_2x_1(k) + b_2u(k) + b_{12}x_2(k-d) \quad (15)$$

将式(14)两边同时乘以 z^{-1} , 式(15)两边同时乘以 z^{-2} (z 为后移算子), 得:

$$x_1(k) = -a_1x_1(k-1) + x_2(k-1) + b_1u(k-1) + b_{11}x_1(k-d-1) \quad (16)$$

$$x_2(k-1) = -a_2x_1(k-2) + b_2u(k-2) + b_{12}x_2(k-d-2) \quad (17)$$

将式(17)代入式(16), 可得:

$$x_1(k) = -a_1x_1(k-1) - a_2x_1(k-2) + b_1u(k-1) + b_2u(k-2) + b_{11}x_1(k-d-1) +$$

$$b_{12}x_2(k-d-2)$$

且由式(13)得:

$$y(k) = x_1(k) + v(k) = -\sum_i^2 a_i x_1(k-i) + \sum_j^2 b_{ij} x_j(k-d-j) + b_2(k)u(k-2) + v(k)$$

因而, 可得变桨故障系统辨识模型为

$$y(k) = \varphi^T(k)\theta(k) + v(k) \quad (18)$$

其中, 参数向量 $\theta(k) = [a_1, a_2, b_{11}, b_{12}, b_2]^T$, 信息向量 $\varphi(k) = [-x_1(k-1), -x_1(k-2), x_1(k-d-1), x_2(k-d-2), u(k-2)]^T$ 。

当系统发生故障时, 特征参数 $\omega_{n,r}$ 及 ζ_r 发生变化, 参数 a_1, a_2, b_2 也随之改变。运用算法及式(18)的辨识模型可以辨识出各参数, 参照其变化判断故障的发生及类型。

2.4 基于辨识模型的 MISG 诊断算法

MISG 算法基于随机梯度算法改进而来。由于随机梯度算法收敛速度慢, 引入了新息长度, 将新息标量扩展为新息向量, 改善其收敛速度^[16]。算法通过多次重复使用当前数据和过去数据递推求出参数, 达到提高参数估计精度的目的。以下是算法结合式(18)系统辨识模型的表达过程。

上述辨识模型的随机梯度算法为

$$\hat{\theta}(k) = \hat{\theta}(k-1) + \frac{\varphi(k)}{r(k)}e(k) \quad (19)$$

$$e(k) = y(k) - \varphi^T(k)\hat{\theta}(k-1) \quad (20)$$

$$r(k) = r(k-1) + \|\varphi(k)\|^2, r(0) = 1 \quad (21)$$

式中: $\hat{\theta}(k)$ ——估计值;

$e(k)$ ——新息。

其中: $\hat{\varphi}(k) = [-\hat{x}_1(k-1), -\hat{x}_1(k-2), \hat{x}_1(k-d-1), \hat{x}_2(k-d-2), u(k-2)]^T$ 。

定义堆积输出向量为 $Y(p,k) = [y(k), y(k-1), \dots, y(k-p+1)]^T$, 信息向量为 $\hat{\Phi}(p,k) = [\hat{\varphi}(k), \hat{\varphi}(k-1), \dots, \hat{\varphi}(k-p+1)]$ 。

为改善算法精度, 将新息标量 $e(k)$ 扩展为新息向量, 定义新息向量为

$$E(p,k) = \begin{bmatrix} e(k) \\ e(k-1) \\ \vdots \\ e(k-p+1) \end{bmatrix}$$

其中: p 为正整数, 称为新息长度。

$$E(p,k) = \begin{bmatrix} y(k) - \hat{\varphi}^T(k)\hat{\theta}(k-1) \\ y(k-1) - \hat{\varphi}^T(k-1)\hat{\theta}(k-1) \\ \vdots \\ y(k-p+1) - \hat{\varphi}^T(k-p+1)\hat{\theta}(k-1) \\ Y(p,k) - \hat{\Phi}^T(p,k)\hat{\theta}(k-1) \end{bmatrix} =$$

$$\eta_a(t) = \begin{cases} 0, & 0 < t \leq 50 \text{ s}, 85 \text{ s} < t \leq 125 \text{ s}, \\ 1, & 50 \text{ s} < 85 \text{ s} \end{cases}$$

表 1 故障特征参数

故障类型	特征参数值
无	$\omega_{n,0} = 11.11 \text{ rad/s}, \zeta_0 = 0.6$
故障 a	$\omega_{n,a} = 3.42 \text{ rad/s}, \zeta_a = 0.9$

由于状态量未知,所以需要用之前参数估计值计算出来的估计状态量代替状态量,可得上述系统的 MISG 算法为

$$\hat{\theta}(k) = \hat{\theta}(k-1) + \frac{\hat{\Phi}(p,k)}{r(k)} E(p,k) \quad (22)$$

$$E(p,k) = Y(p,k) - \hat{\Phi}^T(p,k)\hat{\theta}(k-1) \quad (23)$$

$$r(k) = r(k-1) + \|\hat{\Phi}(p,k)\|^2, \quad (24)$$

$$r(0) = 1$$

$$Y(p,k) = [y(k), y(k-1), \dots, y(k-p+1)]^T \quad (25)$$

$$\hat{\Phi}(p,k) = [\hat{\varphi}(k), \hat{\varphi}(k-1), \dots, \hat{\varphi}(k-p+1)] \quad (26)$$

$$\hat{\varphi}(k) = [-\hat{x}_1(k-1), -\hat{x}_1(k-2), \hat{x}_1(k-d-1), \hat{x}_2(k-d-2), u(k-2)]^T \quad (27)$$

$$\hat{x}(k+1) = \hat{A}\hat{x}(k) + \hat{B}u(k) + \hat{B}_1\hat{x}(t-d) \quad (28)$$

$$\hat{A} = \begin{bmatrix} -\hat{a}_1 & 1 \\ -\hat{a}_2 & 0 \end{bmatrix}, \hat{B} = \begin{bmatrix} 0 \\ \hat{b}_2 \end{bmatrix}, \hat{B}_1 = \begin{bmatrix} 0 & 0 \\ b_{11} & b_{12} \end{bmatrix} \quad (29)$$

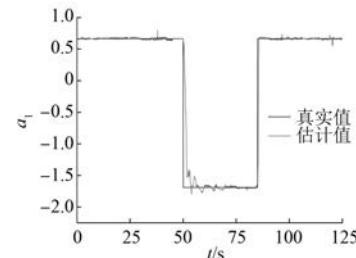
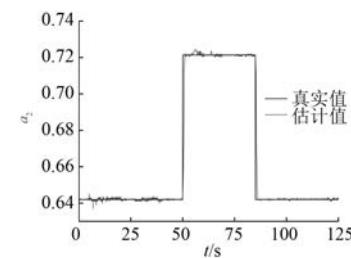
$$\hat{\theta}(k) = [\hat{a}_1, \hat{a}_2, b_{11}, b_{12}, \hat{b}_2]^T \quad (30)$$

3 计算机仿真分析

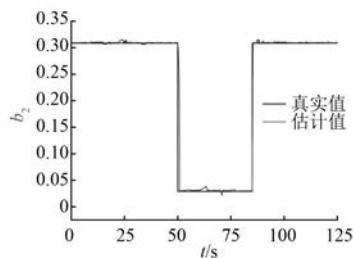
本文以 4.8 MW 级风机基准模型参数为例说明诊断方法有效性。以上简要介绍了风机变桨系统的 3 种故障,仿真中针对单一的液压泄漏故障研究(设两种相异故障不同时发生)。液压泄漏故障在风机运行过程根据故障程度有所不同,特征参数值在一定范围内发生变化。故障 a 特征参数值如表 1 所示^[17],用以验证仿真结果。当液压泄漏故障发生时特征参数发生变化,导致系统动态特性变差,通过故障特征参数代入式(12)可以计算出故障状态下参数实际值如表 2 所示。仿真中设置采样周期 $T_0 = 0.05 \text{ s}$,设 $b_{11} = b_{12} = d = 1$,故障信号设置于 50~85 s,即

参数	无故障时	有故障时
a_1	0.666 7	-1.692 2
a_2	0.642 0	0.721 4
b_2	0.308 6	0.029 2

当 0~50 s 时,风机无故障,稳定运行状态, $\omega_n(t)$ 和 $\zeta(t)$ 分别为 11.11 rad/s、0.6,各参数 a_1 、 a_2 、 b_2 理论实际值为 0.666 7,0.642 0,0.308 6。当 50~85 s 液压泄漏故障发生时,风机不能稳定运行,则特征参数变为故障值,分别为 3.42 rad/s、0.9。因此各参数 a_1 、 a_2 、 b_2 都发生变化,分别为 -1.692 2,0.721 4,0.029 2。在 85 s 后故障消失,参数 a_1 、 a_2 、 b_2 都变为正常值,风机再次稳定运行。MISG 算法对液压故障诊断的仿真结果如图 3~图 5 所示。

图 3 a_1 的真实值与估计值图 4 a_2 的真实值与估计值

由图 3~图 5 可看出,MISG 算法对于风机延时变桨系统故障诊断能够跟踪其参数的大小变

图 5 b_2 的真实值与估计值

化,对该系统具有很好的辨识效果,收敛速度快,可快速判断故障的发生。

4 结语

本文采用基于多新息随机梯度算法和系统辨识理论,估计变桨系统参数,诊断状态延时空间变桨系统故障。当状态延时变桨系统发生故障,其状态及参数随之发生变化时,系统模型内含复杂的非线性关系,使得故障系统更加复杂,更加难以诊断故障。MISG 算法对于延时系统参数估计辨识具有较好的辨识效果,收敛速度快且精度高。先将系统转化为状态空间模型,得到系统辨识模型,然后将 MISG 算法应用于辨识模型,通过跟踪参数的变化和大小实现故障诊断。仿真结果证明了该方法对于诊断风机延时变桨系统故障问题的有效性和可行性。

【参考文献】

- [1] 谢小荣,刘华坤,贺静波,等.直驱风机风电场与交流电网相互作用引发次同步振荡的机理与特性分析[J].中国电机工程学报,2016,36(9): 2366-2372.
- [2] HE D, GUO W, SUN J L. Analysis on the battery failure of wind turbine variable pitch and the adaptability of battery to the environment[J]. Energy & Energy Conservation, 2016, 34(10): 95-97.
- [3] ZHAO H, ZHANG J, WANG G, et al. State estimation based fault detection of hydraulic variable-pitch system for wind turbines [J]. Automation of Electric Power Systems, 2016, 40(22): 100-104.
- [4] XIAO C, JIAO Z, SUN J, et al. Fault prediction of variable pitch system of wind turbine based on wavelet BP neural network[J]. Renewable Energy Resources, 2017, 35(6): 893-899.
- [5] KAMAL E, AITOUCHÉ A, GHORBANI R, et al. Fuzzy scheduler fault-tolerant control for wind energy conversion systems[J]. IEEE Transactions on Control Systems Technology, 2014, 22(1): 119-131.
- [6] YAO Z, YU Y, YAO J. Artificial neural network-based internal leakage fault detection for hydraulic actuators: an experimental investigation [J]. Proceedings of the Institution of Mechanical Engineers Part I Journal of Systems & Control Engineering, 2018, 232(4): 369-382.
- [7] CHEN G, WU Y, FU L, et al. Fault diagnosis of full-hydraulic drilling rig based on RS-SVM data fusion method [J]. Journal of the Brazilian Society of Mechanical Sciences & Engineering, 2018, 40(3): 140.
- [8] 王正宇,张扬帆,段向阳,等.基于 Relief 算法的风电机组故障特征参数提取方法[J].华北电力技术,2017(10): 57-62.
- [9] DAO P B, STASZEWSKI W J, BARSZCZ T, et al. Condition monitoring and fault detection in wind turbines based on cointegration analysis of SCADA data[J]. Renewable Energy, 2017, 116: 107-122.
- [10] POZO F, VIDAL Y. Wind turbine fault detection through principal component analysis and statistical hypothesis testing [J]. Advances in Science & Technology, 2015, 101(1): 45-54.
- [11] 吴定会,翟艳杰.基于系统辨识算法的风力机桨距系统故障诊断[J].信息与控制,2016,45(5): 563-567.
- [12] MA X, DING F. Gradient-based parameter identification algorithms for observer canonical state space systems using state estimates [J]. Circuits Systems & Signal Processing, 2015, 34(5): 1697-1709.
- [13] 洪敏,辛焕海,徐晨博,等.海上风电场与柔性直流输电系统的新型协调控制策略[J].电力系统自动化,2016,40(21): 53-58.
- [14] 吴定会,刘稳,宋锦.基于 SDW-LSI 算法的风力机故障估计与容错控制[J].电力系统保护与控制,2017,45(4): 64-71.
- [15] 李鹏波,胡德文,张纪阳,等.系统辨识[M].北京:中国水利水电出版社,2010.
- [16] XU L, DING F, GU Y, et al. A multi-innovation state and parameter estimation algorithm for a state space system with d-step state-delay [J]. Signal Processing, 2017, 140: 97-103.
- [17] SLOTH C, ESBENSEN T, STOUPRUP J. Robust and fault-tolerant linear parameter-varying control of wind turbines[J]. Mechatronics, 2011, 21(4): 645-659.

收稿日期: 2018-05-31