

基于动态模式的转子系统故障诊断

吴玉香[†], 张景, 王聪

(华南理工大学 自动化科学与工程学院, 广东 广州 510640)

摘要: 以Jeffcott转子系统基础松动-碰摩耦合故障为例, 研究动态模式的转子系统故障诊断方法. 首先, 将转子系统正常和故障时的未知系统动态定义为不同的动态模式, 对其进行学习, 将学到的知识以常数神经网络权值的形式存储, 并建立动态模式库; 然后将当前被监测转子系统与动态模式库中的动态模式进行比较, 根据动态模式的相似性定义, 依据最小误差原则快速判断转子系统与已学过的哪种动态模式相似, 实现故障的快速检测与分离. 仿真结果验证了算法的有效性.

关键词: 故障诊断; 基础松动; 碰摩; RBF神经网络; 动态模式

中图分类号: TP183, TP806+.3 **文献标识码:** A

Fault diagnosis of rotor system based on dynamical models

WU Yu-xiang[†], ZHANG Jing, WANG Cong

(College of Automation Science and Technology, South China University of Technology, Guangzhou Guangdong 510640, China)

Abstract: Taking pedestal looseness and rub-impact coupling fault of a Jeffcott rotor system as an example, we investigate fault diagnosis based on dynamical model for rotor system. First, the unknown dynamics of rotor system in normal and fault conditions are defined as different dynamical models which will be learned. The learned knowledge of the approximated system dynamics is stored in constant neural networks, and the dynamical model bank is established. Second, by comparing the set of dynamical models with the monitoring rotor system, a set of recognition errors are generated, which are taken as the similarity measure between the dynamics of the learned dynamical models and the monitoring rotor system. Therefore, the dynamics of the current system similar to one of the learned dynamics can be rapidly recognized according to the smallest error principle, so that faults can be detected and isolated quickly. Simulation results show the effectiveness of the proposed method.

Key words: fault diagnosis; pedestal looseness; rub-impact; RBF neural networks; dynamical model

1 引言(Introduction)

转子系统的基础松动-碰摩耦合故障在旋转机械中是很普遍的. 基础松动的转子会由于系统的振动量过大而导致碰摩故障的发生, 而对于已发生碰摩的转子系统, 随着碰摩程度的加深和转子引起的长期振动, 会导致基座的周期性振动, 使基础松动与碰摩等故障相互耦合, 引起更复杂的运动现象, 从而影响设备运行的轨迹和性能, 加快设备的磨损速度, 产生不必要的损失. 目前, 已有不少文献对转子系统的松动-碰摩故障的动力学特性进行了研究^[1-3], 而对于这类故障的诊断研究较少, 现有的主要采用基于信号分析的方法^[4-6], 即通过利用频谱分析、小波变换等信号处理技术对耦合故障信号进行分离和提取故障特征并识别

出故障. 由于含基础松动-碰摩耦合故障的转子系统动态具有强非线性、高耦合性, 转子系统的响应极为复杂, 尤其对于高速运转且结构复杂的大型转子系统, 常规故障诊断技术越来越难以满足对大型复杂转子系统提出的可靠性要求, 因而智能诊断技术成为大型复杂系统故障诊断发展的重点方向. 其中, 人工神经网络以其独特的联想、记忆和学习能力在非线性系统的故障诊断领域取得了一定的成效^[7-8], 但这些方法应用于实际中的仍较少. 主要是由于不满足持续激励PE(persistent excitation)条件, 难以实现神经网络对故障动态的准确建模.

如何实现神经网络对非线性系统故障动态的准确建模, 从而避免相同或相似故障再出现时神经网络的

收稿日期: 2015-03-13; 录用日期: 2015-10-19.

[†]通信作者. E-mail: xyuwu@scut.edu.cn; Tel.: +86 13710225325.

本文责任编辑: 张化光.

广东省科技计划项目(2013B090600025, 2015B010133002), 广州市科技计划项目(201508010016)资助.

Supported by Science and Technology Planning Project of Guangdong Province, China (2013B090600025, 2015B010133002) and Science and Technology Planning Project of Guangzhou, China (201508010016).

重复训练,提高故障诊断的快速性及可靠性,成为解决问题的关键.文献[9-10]研究表明,沿回归轨迹的RBF神经元构成的回归子矢量满足PE条件,从而在沿回归轨迹的局部区域内可实现神经网络对非线性系统动态的准确建模.

本文以Jeffcott转子系统基础松动-碰摩耦合故障为例,研究其基于动态模式的故障诊断方法.首先采用RBF神经网络对转子正常和故障时的系统未知动态进行学习,将学到的知识以常数神经网络权值的形式存储,并建立动态模式库;然后将当前被监测转子系统与动态模式库中的动态模式进行比较,根据动态模式的相似性定义,依据最小误差原则快速判断转子系统与已学过的哪种动态模式相似,从而实现故障的快速检测与分离.仿真结果验证了算法的有效性.

2 问题描述(Problem description)

对于运行于复杂动态环境中的大型转子系统,在工程实际中很难获取准确的动力学模型,而含有基础松动-碰摩耦合故障的系统动态更为复杂.下面以Jeffcott转子动力学模型为例展开说明.




图1 基础松动-碰摩故障转子系统模型

Fig. 1 Rotor system model with pedestal looseness and rub-impact fault

如图1所示,假定在一端基座发生基础松动,结合轴承端转轴与基座碰撞的动力学表达式,可得出如下的动力学方程^[11]:

$$\begin{cases} m\ddot{x} + c\dot{x} + F_{xk} = F_x + m\omega^2 \cos\omega t, \\ m\ddot{y} + c(\dot{y} - \dot{y}_1) + F_{yk} = \\ F_y + m\omega^2 \sin\omega t - mg, \\ M'\ddot{y}_1 + c_3\dot{y}_1 + k_3y_1 = \\ c(\dot{y} - \dot{y}_1) + F_{yk} - M'g, \end{cases} \quad (1)$$

式中: x, y 分别是转子圆盘的轴心位移, m 是转子质

量, M' 是基座质量, c 是转轴阻尼系数, u 是圆盘质量偏心系数, ω 是转子角速度, y_1 是转轴在轴承端的垂直位移. F_{xk}, F_{yk} 是转轴弹性力:

$$\begin{cases} F_{xk} = kx + k_1x[x^2 + (y - y_1)^2], \\ F_{yk} = k(y - y_1) + k_1(y - y_1)[x^2 + (y - y_1)^2], \end{cases} \quad (2)$$

其中: k, k_1 分别是转轴线性和非线性刚度系数, F_x, F_y 为转子法向碰摩力 F_n 和切向碰摩力 F_t 在水平和垂直方向上分解的碰摩力, 表示为

$$\begin{cases} F_x \\ F_y \end{cases} = -\frac{(e - \delta)k_r}{e} \begin{bmatrix} 1 & -f \\ f & 1 \end{bmatrix} \begin{cases} x \\ y \end{cases}, \quad (3)$$

其中: $e = \sqrt{x^2 + y^2}$ 是转子的径向位移, δ 是转子系统静止时转子与定子部件之间的空隙, k_r 是静子部件的径向刚度, f 是碰摩部位的库伦摩擦系数.

当发生基础松动时, c_3 和 k_3 分别是基座分段的阻尼系数和刚度系数:

$$c_3 = \begin{cases} c_{31}, & y_1 < 0, \\ c_{32}, & 0 \leq y_1 < \delta_1, \\ c_{33}, & y_1 > \delta_1, \end{cases} \quad k_3 = \begin{cases} k_{31}, & y_1 < 0, \\ k_{32}, & 0 \leq y_1 < \delta_1, \\ k_{33}, & y_1 > \delta_1, \end{cases} \quad (4)$$

其中 δ_1 是基础松动最大间隙.

引入无量纲变换:

$$\begin{aligned} X &= \frac{x}{\delta}, \quad Y = \frac{y}{\delta}, \quad Y_1 = \frac{y_1}{\delta}, \quad \tau = \omega_0 t, \quad \bar{\omega} = \frac{\omega}{\omega_0}, \\ \mu &= \frac{u}{\delta}, \quad \xi = \frac{c}{2m\omega_0}, \quad \alpha = \frac{k_1\delta^2}{k}, \quad \beta = \frac{k_r}{k}, \\ G &= \frac{g}{\omega_0^2\delta}, \quad s = \frac{M'}{m}, \quad \xi_3 = \frac{c_3}{2M'\omega_0}, \quad \omega_0^2 = \frac{k}{m}, \\ \omega_2^2 &= \frac{k_3}{M'}, \quad \alpha_1 = \frac{\omega_2^2}{\omega_0^2} = \frac{k_3}{M'} \cdot \frac{m}{k}, \end{aligned}$$

其中: ω_0 是转子转速频率在固有频率 f_0 时的转子角速度, ω_2 是基座固有频率(角速度形式表示), $\bar{\omega}$ 是频率比, ξ 和 ξ_3 分别是转子和基座的阻尼比, α_1, α 和 β 是刚度比, μ 是偏心量, $E = \sqrt{X^2 + Y^2}$, 则含基础松动与碰摩耦合故障的转子系统无量纲微分方程为

$$\begin{cases} \ddot{X} + 2\xi\dot{X} + X + \alpha X[X^2 + (Y - Y_1)^2] + \\ \beta(1 - \frac{1}{E})(X - fY) = \mu\bar{\omega}^2 \cos\bar{\omega}\tau, \\ \ddot{Y} + 2\xi(\dot{Y} - \dot{Y}_1) + (Y - Y_1) + \alpha(Y - Y_1) \times \\ [X^2 + (Y - Y_1)^2] + \beta(1 - \frac{1}{E})(fX + Y) = \\ \mu\bar{\omega}^2 \sin\bar{\omega}\tau - G, \\ \ddot{Y}_1 + 2\xi_3\dot{Y}_1 + \alpha_1 Y_1 = \\ \frac{2\xi}{s}(\dot{Y} - \dot{Y}_1) + \frac{1}{s}(Y - Y_1) + \\ \frac{\alpha}{s}(Y - Y_1)[X^2 + (Y - Y_1)^2] - G, \end{cases} \quad (5)$$

引入状态变换:

$$\begin{aligned} X_1 &= X, X_2 = \dot{X}, X_3 = Y, \\ X_4 &= \dot{Y}, X_5 = Y_1, X_6 = \dot{Y}_1. \end{aligned}$$

令 $\phi(\mathbf{Z}) = [\phi_1 \ \phi_2 \ \phi_3]^T$ 为转子系统未知动态, $\mathbf{Z} = \{X_1, X_2, X_3, X_4, X_5, X_6\}$.

$$\begin{cases} \phi_1(\mathbf{Z}) = -2\xi X_2 - X_1 - \alpha X_1 [X_1^2 + (X_3 - X_5)^2] - \beta(1 - \frac{1}{E})(X_1 - fX_3), \\ \phi_2(\mathbf{Z}) = -2\xi(X_4 - X_6) - (X_3 - X_5) - \alpha(X_3 - X_5)[X_1^2 + (X_3 - X_5)^2] - \beta(1 - \frac{1}{E})(fX_1 + X_3) - G, \\ \phi_3(\mathbf{Z}) = -2\xi_3 X_6 - \alpha_1 X_5 + \frac{2\xi}{s}(X_4 - X_6) + \frac{1}{s}(X_3 - X_5) + \frac{\alpha}{s}(X_3 - X_5)[X_1^2 + (X_3 - X_5)^2] - G. \end{cases} \quad (6)$$

由此, 式(5)可改写成如下—阶微分方程组:

$$\begin{cases} \dot{X}_1 = X_2, \dot{X}_2 = \phi_1(\mathbf{Z}) + \mu\bar{\omega}^2 \cos \bar{\omega}\tau, \\ \dot{X}_3 = X_4, \dot{X}_4 = \phi_2(\mathbf{Z}) + \mu\bar{\omega}^2 \sin \bar{\omega}\tau, \\ \dot{X}_5 = X_6, \dot{X}_6 = \phi_3(\mathbf{Z}). \end{cases} \quad (7)$$

由于含有基础松动-碰摩耦合故障的转子系统主要运动形式为周期、倍周期、拟周期运动, 因此全文可假定故障发生前后, 转子系统轨迹为回归轨迹.

3 故障动态的学习 (Fault system dynamics learning)

不同的碰摩程度、松动间隙、耦合强度、故障位置等因素共同作用下的基础松动-碰摩耦合故障对系统动态的影响不同, 本部分利用RBF神经网络对正常运行及各种基础松动-碰磨故障下的未知系统动态进行学习, 并建立相应的动态模式库.

由式(1)或式(5)可知, 对于整个转子系统, 轴承端的振动与转轴的振动相互耦合, 轴承端的振动规律直接反映到了转轴的振动规律, 为了提高诊断效率, 这里只对转子水平和垂直方向的未知动态进行学习. 假定转子系统状态可测, 采用如下RBF神经网络进行学习:

$$\begin{cases} \dot{\hat{X}}_2 = -a_1(\hat{X}_2 - X_2) + \hat{\mathbf{W}}_1^T \mathbf{S}_1(\mathbf{Z}) + \mu\bar{\omega}^2 \cos \bar{\omega}\tau, \\ \dot{\hat{X}}_4 = -a_2(\hat{X}_4 - X_4) + \hat{\mathbf{W}}_2^T \mathbf{S}_2(\mathbf{Z}) + \mu\bar{\omega}^2 \sin \bar{\omega}\tau, \end{cases} \quad (8)$$

式中: $a_i > 0 (i = 1, 2)$ 是设计常数, \hat{X}_{2i} 是 X_{2i} 的估计值, RBF神经网络 $\hat{\mathbf{W}}_i^T \mathbf{S}_i(\mathbf{Z})$ 用以逼近未知动态 $\phi_i(\mathbf{Z})$:

$$\phi_i(\mathbf{Z}) = \hat{\mathbf{W}}_i^T \mathbf{S}_i(\mathbf{Z}) + \hat{\varepsilon}_i = \mathbf{W}_i^{*T} \mathbf{S}_i(\mathbf{Z}) + \varepsilon_i, \quad (9)$$

式中: $\hat{\mathbf{W}}_i = [w_{i1} \ \dots \ w_{iM_i}]^T \in \mathbb{R}^{M_i}$ 是神经网络权值矢量 ($M_i > 1$ 为神经元个数, $i = 1, 2$),

$\mathbf{S}_i(\mathbf{Z}) = [s_{i1}(\|\mathbf{Z} - \boldsymbol{\chi}_{i1}\|), \dots, s_{iM_i}(\|\mathbf{Z} - \boldsymbol{\chi}_{iM_i}\|)]^T$, \mathbf{Z} 是神经网络的输入矢量, 其中高斯函数

$$s_{ij}(\|\mathbf{Z} - \boldsymbol{\chi}_{ij}\|) = \exp[-(\mathbf{Z} - \boldsymbol{\chi}_{ij})^T(\mathbf{Z} - \boldsymbol{\chi}_{ij})/\eta_{ij}^2]$$

为普遍使用的一类径向基函数 ($j = 1, \dots, M_i$), $\boldsymbol{\chi}_{ij}$ 为中心点, η_{ij} 为中心宽度, 当 $\|\mathbf{Z}\| \rightarrow \infty$ 时, $s_{ij}(\|\mathbf{Z} - \boldsymbol{\chi}_{ij}\|) \rightarrow 0$, $\hat{\varepsilon}_i$ 为神经网络 $\hat{\mathbf{W}}_i^T \mathbf{S}_i(\mathbf{Z})$ 的逼近误差. \mathbf{W}_i^* 是最优神经网络权值矢量, $|\varepsilon_i| > \varepsilon_i^*$ ($\varepsilon_i^* > 0$ 且值很小).

式(8)中的神经网络权值 $\hat{\mathbf{W}}_i$ 更新率取为

$$\dot{\hat{\mathbf{W}}}_i = \dot{\tilde{\mathbf{W}}}_i = -\Gamma_i \mathbf{S}_i(\mathbf{Z}) \tilde{z}_i - \sigma_i \Gamma_i \hat{\mathbf{W}}_i, \quad (10)$$

式中: $\tilde{\mathbf{W}}_i = \hat{\mathbf{W}}_i - \mathbf{W}_i^*$ 为权值估计误差, $\tilde{z}_i = \hat{X}_{2i} - X_{2i}$ 为速度估计误差, $\Gamma_i, \sigma_i > 0$ 是设计参数, 且 σ_i 的值很小.

由式(7)-(10)可构成如下辨识误差系统:

$$\begin{bmatrix} \dot{\tilde{z}}_i \\ \dot{\tilde{\mathbf{W}}}_i \end{bmatrix} = \begin{pmatrix} -a_i & \mathbf{S}_i^T(\mathbf{Z}) \\ -\Gamma_i \mathbf{S}_i^T(\mathbf{Z}) & 0 \end{pmatrix} \begin{bmatrix} \tilde{z}_i \\ \tilde{\mathbf{W}}_i \end{bmatrix} + \begin{bmatrix} -\varepsilon_i \\ -\sigma_i \Gamma_i \hat{\mathbf{W}}_i \end{bmatrix}. \quad (11)$$

据RBF神经网络的局部属性, 沿着系统轨迹, 式(11)可改写为如下形式:

$$\begin{bmatrix} \dot{\tilde{z}}_i \\ \dot{\tilde{\mathbf{W}}}_{i\zeta} \end{bmatrix} = \begin{pmatrix} -a & \mathbf{S}_{i\zeta}^T(\mathbf{Z}) \\ -\Gamma_i \mathbf{S}_{i\zeta}^T(\mathbf{Z}) & 0 \end{pmatrix} \begin{bmatrix} \tilde{z}_i \\ \tilde{\mathbf{W}}_{i\zeta} \end{bmatrix} + \begin{bmatrix} -\varepsilon_{i\zeta} \\ -\sigma_i \Gamma_i \hat{\mathbf{W}}_{i\zeta} \end{bmatrix}, \quad (12)$$

$$\dot{\hat{\mathbf{W}}}_{i\bar{\zeta}} = \dot{\tilde{\mathbf{W}}}_{i\bar{\zeta}} = -\Gamma_i \mathbf{S}_{i\bar{\zeta}}(\mathbf{Z}) \tilde{z}_i - \sigma_i \Gamma_i \hat{\mathbf{W}}_{i\bar{\zeta}}, \quad (13)$$

式中: 下标 $(\cdot)_\zeta$ 和 $(\cdot)_{\bar{\zeta}}$ 分别代表靠近和远离系统轨迹的区域, $\mathbf{S}_{i\zeta}(\mathbf{Z})$ 为 $\mathbf{S}_i(\mathbf{Z})$ 的子矢量, $\hat{\mathbf{W}}_{i\zeta}$ 为相应的权值子矢量, $\varepsilon_{i\zeta} = \varepsilon_i - \hat{\mathbf{W}}_{i\zeta}^T \mathbf{S}_{i\zeta}(\mathbf{Z})$. 对于RBF神经网络, 由于远离系统轨迹, $|\hat{\mathbf{W}}_{i\bar{\zeta}}^T \mathbf{S}_{i\bar{\zeta}}(\mathbf{Z})|$ 的值很小, 因而可知 $\varepsilon_{i\zeta} = O(\varepsilon_i)$. 又因为 $\|\sigma_i \Gamma_i \hat{\mathbf{W}}_{i\zeta}\|$ 也很小, 故可将式(12)看成其标称系统的扰动系统.

因为转子系统轨迹为回归轨迹, 则神经网络的输入 \mathbf{Z} 也是回归信号, 据文献[10]定理2.7可知, $\mathbf{S}_i(\mathbf{Z})$ 的回归子矢量 $\mathbf{S}_{i\zeta}(\mathbf{Z})$ 满足PE条件, 进而可知系统(12)的标称系统是指稳定的^[12]. 再由文献[13]的引理5.2可知, 速度估计误差 \tilde{z}_i 和权值估计误差 $\tilde{\mathbf{W}}_{i\zeta}$ 均收敛到零的小邻域内, 而中心远离系统轨迹的神经元权值则只被轻微的调节, 即 $\hat{\mathbf{W}}_{i\bar{\zeta}}$ 和 $\hat{\mathbf{W}}_{i\bar{\zeta}}^T \mathbf{S}_{i\bar{\zeta}}(\mathbf{Z})$ 基本保持为零.

根据收敛结果, 通过 $\bar{\mathbf{W}}_i = \text{mean}_{t \in [t_a, t_b]} \hat{\mathbf{W}}_i(t)$ ($t_b > t_a > 0$ 代表暂态过程之后的一个时间段) 可得神经网络

的常数权值. 则沿着系统轨迹, 未知系统动态 $\phi_i(\mathbf{Z})$ 可用 $\bar{\mathbf{W}}_{i_c}^T \mathbf{S}_{i_c}(\mathbf{Z})$ 表示, 即

$$\phi_i(\mathbf{Z}) = \bar{\mathbf{W}}_{i_c}^T \mathbf{S}_{i_c}(\mathbf{Z}) + \bar{\varepsilon}_{i_c}, \quad (14)$$

式中 $|\bar{\varepsilon}_{i_c}| = O(|\varepsilon_i^*|)$.

由于 $\bar{\mathbf{W}}_{i_c}$ 和 $\bar{\mathbf{W}}_{i_c}^T \mathbf{S}_{i_c}(\mathbf{Z})$ 的值很小, 据式(14)可知, 沿着系统轨迹, 整个RBF网络 $\bar{\mathbf{W}}_{i_c}^T \mathbf{S}_{i_c}(\mathbf{Z})$ 可逼近系统未知动态 $\phi_i(\mathbf{Z})$, 即

$$\phi_i(\mathbf{Z}) = \bar{\mathbf{W}}_i^T \mathbf{S}_i(\mathbf{Z}) + \bar{\varepsilon}_i, \quad (15)$$

式中: $\bar{\varepsilon}_i = \bar{\varepsilon}_{i_c} - \bar{\mathbf{W}}_{i_c}^T \mathbf{S}_{i_c}(\mathbf{Z})$, $|\bar{\varepsilon}_i| = O(|\varepsilon_i^*|)$.

式(15)表示, 沿着系统轨迹, 时变的系统未知动态 $\phi_i(\mathbf{Z})$ 可以用神经网络进行局部准确建模, 且其表现形式是时不变的.

通过分别对正常模式和各种故障模式(假设有 N 种故障类型)下的系统未知动态进行学习, 可相应地获得一组常数神经网络权值, 记为 $\bar{\mathbf{W}}_i^s (i = 1, 2, s = 0, \dots, N)$, 其中 $s = 0$ 对应正常模式). 这些常数神经网络权值作为相应运行模式下的系统未知动态 ϕ_i^s 的静态表达(以时不变且空间分布的方式)被方便地存储起来, 建立动态模式库, 并运用于后续的故障检测与诊断中.

根据学习结果, 构造如下 $N + 1$ 个动态估计器来表征 $N+1$ 个动态模式, 建立动态模式库:

$$\begin{cases} \dot{\bar{X}}_2^s = -b_1(\bar{X}_2^s - X_2) + \bar{\mathbf{W}}_1^{sT} \mathbf{S}_1(\mathbf{Z}) + \mu\bar{\omega}^2 \cos \bar{\omega}\tau, \\ \dot{\bar{X}}_4^s = -b_2(\bar{X}_4^s - X_4) + \bar{\mathbf{W}}_2^{sT} \mathbf{S}_2(\mathbf{Z}) + \mu\bar{\omega}^2 \sin \bar{\omega}\tau, \end{cases} \quad (16)$$

式中: $b_i > 0 (i = 1, 2)$ 为设计常数, X_{2i} 为被监测转子的速度, \bar{X}_{2i}^s 为动态估计器 s 的状态($s = 0, \dots, N$).

式(16)表示的动态估计器中嵌入了在学习中所获取的动态模式的内部动态. 基于模型的故障诊断方法需要被监测系统准确的系统模型, 任何建模误差及外界干扰都会对诊断性能产生影响. 而上述学习方法能够实现系统未知动态的局部准确神经网络建模. 另外, 当有外界干扰时, 通过适当选取参数可降低其影响, 提高建模精度^[14].

4 故障的诊断(Fault diagnosis)

本部分将当前被监测转子系统与动态模式库中的动态模式进行比较, 根据动态模式的相似性定义^[10], 依据最小误差原则快速判断转子系统与已学过的哪种动态模式相似, 实现故障的快速诊断. 将被监测转子系统(6)与动态估计器(16)进行比较, 可得到如下的残差系统:

$$\begin{aligned} \dot{\tilde{X}}_{2i}^s &= -b_i \tilde{X}_{2i}^s + \bar{\mathbf{W}}_i^{sT} \mathbf{S}_i(\mathbf{Z}) - \phi_i(\mathbf{Z}) = \\ &= -b_i \tilde{X}_{2i}^s + \tilde{\phi}_i(\mathbf{Z}), \end{aligned} \quad (17)$$

式中: $\tilde{X}_{2i}^s = \bar{X}_{2i}^s - X_{2i}$ 为速度残差, $\tilde{\phi}_i(\mathbf{Z})$ 为被监测转子系统与动态估计器 s 之间的动态差异.

残差系统(17)是稳定的, 其证明可参考文献[9]. 根据文献[9]定理2可知, 残差 \tilde{X}_{2i}^s 将近似正比于 $\tilde{\phi}_i(\mathbf{Z})$. 这意味着当转子系统发生故障 s 后, 在有限的时间内, 与动态估计器 s 产生的残差就会变得很小, 而其他不匹配的动态估计器 $k (k \in \{0, 1, \dots, N\} / \{s\})$ 产生的残差则会变得较大, 即残差最小的动态估计器的系统动态与当前转子系统动态最匹配^[15-16]. 当 $\tilde{\phi}_i(\mathbf{Z})$ 改变符号时, 不匹配动态估计器产生的残差可能接近于零, 从而引起误判. 因此用残差的平均 L_1 范数来决策

$$\|\tilde{X}_{2i}^s\| = \frac{1}{T} \int_{t-T}^t |\tilde{X}_{2i}^s| d\tau, \quad t > T, \quad (18)$$

式中 T 是被监测转子系统的运行周期.

在本文提出的转子系统故障诊断过程中, 不需要重新辨识当前转子系统的未知动态, 而是通过监测当前转子系统与各动态估计器的残差范数的变化来判断当前转子系统的运行状态, 进行故障检测和分离. 具体的故障诊断流程如图2.

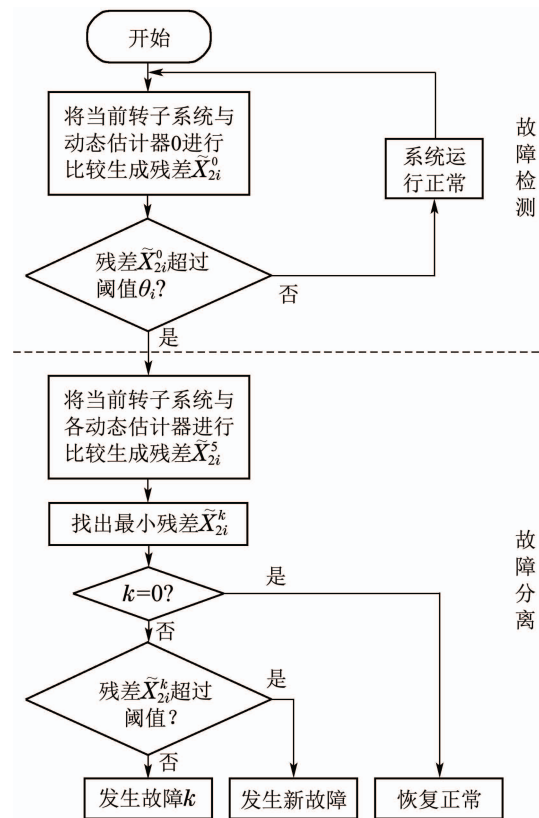


图2 故障诊断流程

Fig. 2 Fault diagnosis procedure

图2中, 检测阈值 θ_i 依据转子系统正常运行时估计器0的残差最大值来设定(一般很小). 若有新故障发生, 则按照上一部分所述方法来学习新故障, 获得相应一组常数神经网络权值, 并按式(16)构造新的动态估计器. 显然, 通过不断地学习新故障, 所学故障知识不断地丰富, 故障诊断的精度也会随之提高.

5 仿真研究(Simulation)

采用由式(1)表示的Jeffcott转子动力学模型为例进行仿真实验. 该系统无量纲化后的主要参数有^[11]:

$$\begin{aligned} f_0 &= 25 \text{ Hz}, \delta = 1.6 \times 10^{-4} \text{ m}, \xi = 0.135, \\ \delta_1 &= 1 \times 10^{-5} \text{ m}, \mu = 0.8, f = 0.15, \alpha = 1, \\ \beta &= 3, s = 4, c_{11} = c_{13} = 10, c_{12} = 4, \\ k_{31} &= k_{33} = 0.405, k_{32} = 0.135, \end{aligned}$$

其中 f_0 为固有频率.

仿真中考虑转子系统的4种运行模式, 相应的系统参数变化如下^[7,11]:


- 1) 转子未发生故障(正常模式): $\bar{\omega} = 0.75$, 其余参数不变;
- 2) 基础松动-无碰摩(故障1): $\bar{\omega} = 0.9$, 其余参数不变;
- 3) 基础松动-局部轻微碰摩耦合(故障2): $\bar{\omega} = 1$, 其余参数不变;
- 4) 基础松动-严重碰摩耦合(故障3): $\bar{\omega} = 1.1$, 其余参数不变.

5.1 故障动态的学习(Fault system dynamics learning)


按式(8)和式(11)对4种运行模式进行学习, 由于各模式学习方法相同, 仅对故障3的学习过程作说明.

构造RBF神经网络 $\hat{W}_i^T S_i(\mathbf{Z})$ ($i = 1, 2$), 节点数 $M_i = 15876$, 中心均匀分布于区域 $[-1.08, 1.08] \times [-1.2, 1.2] \times [-1.2, 1.2] \times [-1.2, 1.2] \times [-0.12, 0.12] \times [-1.2, 1.2]$ 上, 中心宽度为0.24. 系统初始条件为 $X_1(0) = 0.1, X_2(0) = X_3(0) = X_4(0) = X_5(0) = X_6(0) = 0$; 神经网络权值初始值为0; 设计参数 $a = 4, \Gamma = 2, \sigma = 0.0001$.

故障3的学习结果如图3-4所示. 其中, 图3为部分神经网络权值 \hat{W}_i^3 的收敛曲线, 可以看出其中中心靠近系统轨迹的神经元权值收敛到常数, 而中心远离系统轨迹的神经元权值收敛到零的附近. 图4为常数神经网络 $\bar{W}_i^{3T} S_i(\mathbf{Z})$ 逼近转子系统未知动态 ϕ_i^3 .




(a) 部分权值 \hat{W}_{1c}^3 收敛




(b) 部分权值 \hat{W}_{2c}^3 收敛

图3 部分权值 \hat{W}_{ic}^3 收敛

Fig. 3 Partial parameter convergence



(a) 用 $\bar{W}_1^{3T} S_1(\mathbf{Z})$ (*)逼近 ϕ_1^3 (-)



(b) 用 $\bar{W}_2^{3T} S_2(\mathbf{Z})$ (*)逼近 ϕ_2^3 (-)

图4 常数神经网络逼近系统未知动态

Fig. 4 Unknown dynamics approximation with constant neural networks

通过对上述4种转子运行模式的学习可获得4组常数神经网络权值 \bar{W}_i^s ($s = 0, 1, 2, 3$), 按式(16)构造包含常数神经网络权值的动态估计器, 建立动态模式库.


5.2 故障的诊断(Fault diagnosis)

将当前被监测转子系统与模式库中的各动态模式进行比较, 根据动态模式的相似性定义及最小误差原


则对转子系统进行故障诊断. 仿真中假设转子系统已经在正常状态下运行, 并在1s时刻发生了故障1, 之后又在2s时刻发生了故障2, 然后在3s时刻发生了故障3. 这里设定检测阈值为 $\theta_1 = \theta_2 = 0.01$.

被监测转子系统与各动态估计器之间的速度残差范数曲线如图5所示. 其中, $L_X^0, L_X^1, L_X^2, L_X^3$ 分别为被监测转子系统与各动态估计器在X方向上的速度残差范数, $L_Y^0, L_Y^1, L_Y^2, L_Y^3$ 分别为被监测转子系统与各动态估计器在Y方向上的速度残差范数.

从图5中可知, 在1s之前动态估计器0的残差范数 $L_X^0(L_Y^0)$ 接近于零, 可判断系统工作正常; 1s时刻动态估计器0的残差范数 $L_X^1(L_Y^1)$ 开始增大并迅速超过阈值, 此时检测出转子系统发生故障, 开始进行故障分离; 由于1s到2s这段时间动态估计器1的残差范数 $L_X^1(L_Y^1)$ 最小, 因此可判断故障1发生; 在2s到3s这段时间, 动态估计器2的残差范数 $L_X^2(L_Y^2)$ 最小, 因此可判断故障2发生, 在3s到4s这段时间之后, 动态估计器3的残差范数 $L_X^3(L_Y^3)$ 最小, 因此可判断故障3发生.



(a) X方向残差范数变化曲线



(b) Y方向残差范数变化曲线

图5 故障的检测和分离

Fig. 5 Fault detection and isolation

仿真结果表明, 本文设计的诊断方法可动态实时地监测转子系统的动态变化, 快速识别出当前转子故障动态, 实现转子系统故障的快速诊断.

6 结论(Conclusions)

本文以转子系统基础松动-耦合故障为例, 研究基于动态模式的转子系统故障诊断方法. 本文的故障诊

断方法包括两个阶段: 学习阶段和故障诊断阶段. 在学习阶段, 采用RBF神经网络对不同故障模式下的转子系统未知动态进行学习, 将学到的知识以常数神经网络权值的方式存储, 实现神经网络对转子系统未知故障动态的局部准确建模, 并通过构建一组包含常值RBF网络的动态估计器建立动态模式库. 在故障诊断阶段, 将被监测转子系统与模式库中各动态估计器比较, 产生一组 L_1 范数形式的识别误差, 依据最小误差原则实现转子系统故障的快速检测与分离.

参考文献(References):

- [1] WANG Zongyong, WU Jingdong, WEN Bangchun. Research on pedestal looseness and rub-impact faults of rotor system with slowly varying mass [J]. *Journal of Vibration Engineering*, 2005, 18(2): 167 – 171.
(王宗勇, 吴敬东, 闻邦椿. 质量慢变转子系统的松动与碰摩故障研究 [J]. 振动工程学报, 2005, 18(2): 167 – 171.)
- [2] CHEN Guo. Nonlinear dynamic response analysis of rotor-ball bearing system including unbalance-rubbing-looseness coupled faults [J]. *Journal of Vibration and Shock*, 2008, 27(9): 100 – 104.
(陈果. 含不平衡-碰摩-基础松动耦合故障的转子-滚动轴承系统非线性动力响应分析 [J]. 振动与冲击, 2008, 27(9): 100 – 104.)
- [3] LUO Y G, ZHANG S H, WU B, et al. Stability of periodic motion of nonlinear elastics rotor-bearing system with coupling faults of pedestal looseness and rub-impact [C] // *International Conference on Measuring Technology and Mechatronics Automation*. New York: Curran Associates, Inc., 2010: 469 – 472.
- [4] QU Xiuxiu, CHEN Guo, QIAO Baodong. Signal separation technology for dynamic model of rotor with unbalance- rubbing-looseness coupled faults [J]. *Journal of Vibration and Shock*, 2011, 30(6): 74 – 77.
(曲秀秀, 陈果, 乔保栋. 不平衡-碰摩-基础松动耦合故障的转子动力学建模与盲分离研究 [J]. 振动与冲击, 2011, 30(6): 74 – 77.)
- [5] WU F Q, MENG G. Compound rub malfunctions feature extraction based on full spectrum cascade analysis and SVM [J]. *Mechanical Systems and Signal Processing*, 2006, 20(8): 2007 – 2021.
- [6] ZHANG Jialiang, CAO Jianfu, GAO Feng, et al. Fault diagnosis of complex system based on nonlinear spectrum and kernel principal component analysis [J]. *Control Theory & Applications*, 2012, 29(12): 1558 – 1564.
(张家良, 曹建福, 高峰, 等. 综合非线性频谱与核主元分析的复杂系统故障诊断方法 [J]. 控制理论与应用, 2012, 29(12): 1558 – 1564.)
- [7] HAN Qingkai, YU Tao, WANG Deyou, et al. *Nonlinear Vibration Analysis and Diagnosis of Fault Rotor System* [M]. Beijing: The Science Publishing Company, 2010.
(韩清凯, 于涛, 王德友, 等. 故障转子系统的非线性振动分析与诊断方法 [M]. 北京: 科学出版社, 2010.)
- [8] YIN Gang, ZHANG Yingtang, LI Zhining, et al. Fault diagnosis method based on online semi-supervised learning [J]. *Journal of Vibration Engineering*, 2012, 25(6): 637 – 642.
(尹刚, 张英堂, 李志宁, 等. 基于在线半监督学习的故障诊断方法研究 [J]. 振动工程学报, 2012, 25(6): 637 – 642.)
- [9] WANG C, HILL D J. Deterministic learning and rapid dynamical pattern recognition [J]. *IEEE Transactions on Neural Networks*, 2007, 18(3): 617 – 630.
- [10] WANG C, HILL D J. *Deterministic Learning Theory for Identification, Recognition and Control* [M]. BocaRaton: CRC Press, 2009.
- [11] LUO Yuegang. *Study on some nonlinear dynamics problems of rotor system with faults and intelligent diagnosis method* [D]. Shenyang: Northeastern University, 2002.

- (罗跃刚. 转子系统故障的若干非线性动力学问题及智能诊断研究 [D]. 沈阳: 东北大学, 2002.)
- [12] LIU T F, WANG C, HILL D J. Learning from neural control of nonlinear systems in normal form [J]. *Systems & Control Letters*, 2009, 58(1): 633 – 638.
- [13] KHALIL H K. *Nonlinear Systems* [M]. 2nd ed. Englewood Cliffs, NJ: Prentice-Hall, 1996.
- [14] YUAN C Z, WANG C. Performance of deterministic learning in noisy environments [J]. *Neurocomputing*, 2012, 78(1): 72 – 82.
- [15] WU Yuxiang, ZHANG Jing, WANG Cong. Fault diagnosis of cracked rotor systems based on radial basis function neural networks [J]. *Control Theory & Applications*, 2014, 31(8): 1061 – 1068.
(吴玉香, 张景, 王聪. 基于径向基函数神经网络的转子系统裂纹故障诊断 [J]. 控制理论与应用, 2014, 31(8): 1061 – 1068.)
- [16] WU Yuxiang, ZHANG Jing, WANG Cong. Fault diagnosis of robot based on deterministic learning [J]. *Transactions of Beijing Institute of Technology*, 2015, 35(4): 403 – 408.
(吴玉香, 张景, 王聪. 基于确定学习的机器人故障诊断 [J]. 北京理工大学学报, 2015, 35(4): 403 – 408.)

作者简介:

吴玉香 (1968–), 女, 教授, 主要研究方向为非线性系统的自适应神经网络控制、机器人控制及转子系统故障诊断等, E-mail: xyuwu@scut.edu.cn;

张景 (1989–), 女, 硕士, 主要研究方向为非线性系统的智能故障诊断等, E-mail: jingzh198@126.com;

王聪 (1968–), 男, 教授, 主要研究方向为确定学习理论、动态模式识别、基于模式的控制等, E-mail: wangcong@scut.edu.cn.