

文章编号 1004-924X(2018)07-1728-13

## 在轨飞轮故障诊断混合框架设计

赵琳, 王艺鹏, 郝勇\*

(哈尔滨工程大学自动化学院, 黑龙江哈尔滨 150001)

**摘要:**为提升飞轮的可靠性,本文对飞轮故障诊断技术进行了研究。通过对基于数学解析模型与基于智能计算的故障诊断方法的对比研究,提出了一种基于神经网络的混合故障诊断方法。该方法首先使用数学解析模型与原系统输出的差值作为一级残差;而后利用该一级残差以及系统可测状态对神经网络进行训练;然后使用混合模型输出的二级残差对系统故障进行检测;最后以飞轮注入母线电压以及电枢电流故障对该方法进行验证:在存在母线电压故障工况下混合模型避免了解析模型电流估计的发散问题,与单神经网络模型相比最大跟踪误差降低了 44%。在存在电流故障时,不同的转速工况下与两种单模型相比混合模型的最大跟踪误差降低了 90%,跟踪方差减小了 10 倍以上。混合方法可以有效解决由于解析模型存在建模误差引起的故障诊断不够准确的问题以及由于缺乏训练数据所引起的单神经网络模型不能适应新工况的故障诊断问题。

**关键词:**故障诊断;神经网络;混合模型;建模误差;非线性

中图分类号:V9 文献标识码:A doi:10.3788/OPE.20182607.1728

## Design of hybrid frame for on-orbit flywheel fault diagnosis

ZHAO Lin, WANG Yi-peng, HAO Yong\*

(Control Engineering, Harbin Engineering University, Harbin 150001, China)

\* Corresponding author, E-mail:haoyong@hrbeu.edu.cn

**Abstract:** In order to improve flywheel reliability, flywheel fault diagnosis technology was studied. A hybrid fault diagnosis method based on a neural network was proposed, which compares the mathematical analysis model with the flywheel fault diagnosis based on intelligent computing. In this method, the difference between the mathematical model and the original system output was used as the first-order residual. Then, the first-order residual and the system measurements were used to train the neural network. Finally, the second-order residual of the mixed model output was used to detect the system fault. This method was validated using the flywheel injection bus voltage and armature current faults. Under the bus voltage fault working conditions, the hybrid model avoided the divergence problem of current estimation because of the analytical model, which reduced the maximum tracking error by 44% compared with a single neural network model. Under the current fault working conditions, the maximum tracking error of the hybrid model was reduced by 90% and the tracking variance was reduced by more than 10 times under different speed conditions compared with two single neural network models. These results illustrate that the hybrid method can effectively solve the

收稿日期:2017-12-15;修订日期:2018-02-01.

基金项目:国家自然科学基金资助项目(No. 61773132);黑龙江自然科学基金面上资助项目(No. F2017005);中央高校基本科研业务费(No. HEUCFP201768)

problem of inaccurate fault diagnosis due to the existence of modeling errors in the analytical model, as well as the problem of a single neural network model being unable to adapt to fault diagnosis corresponding to new working conditions because of the lack of training data.

**Key words:** fault diagnosis; neural network; hybrid method; modeling error; nonlinear

## 1 引言

航天器控制分系统的故障比例高达航天器故障总量的 30%,而执行器故障又占到控制分系统故障总量的 50%以上<sup>[1]</sup>。为了提高空间飞行器能源效率,保证装备安全,增强空间任务的可靠性和故障容错能力,针对在轨运行时的执行机构展开故障诊断技术的研究十分必要。

目前主要的成熟故障诊断方法主要分为:基于模型的诊断方法以及数据驱动的方法。基于模型的故障诊断研究始于 20 世纪 70 年代,Beard 提出了基于模型的故障检测方法,即所谓的故障检测滤波器<sup>[3]</sup>。Frank 明确给出了基于模型的故障诊断的框架,并将基于模型的故障诊断研究分类为:基于观测器的方法<sup>[4-6]</sup>、奇偶空间法<sup>[7-8]</sup>及基于参数辨识的方法<sup>[9-10]</sup>。近 50 年,对鲁棒性诊断、非线性系统诊断以及自适应诊断等问题的研究也得到了发展<sup>[11-12]</sup>。基于解析模型的方法依赖于精确描述系统动力学行为及其主要特征的数学解析模型。文献<sup>[13]</sup>中将数据驱动的诊断方法分为基于统计分析的方法以及非统计分析的方法,基于统计分析的方法如 PCA、PLS、ICA 和 SVM 等已经大量应用于实际工程并取得了良好效果;非统计分析方法如神经网络、模糊逻辑等也取得了一些应用成果。Patton 在 1999 年提出了使用神经网络进行故障诊断的方法<sup>[14]</sup>,由于神经网络能够产生输入\输出映射关系,并在适当的假设前提下,能以任意设定的准确度逼近任意的非线性过程,所以该类方法得到了广泛的研究。使用适当的神经网络模型可以利用过程运行数据实现系统建模<sup>[15-17]</sup>以及对未知系统特性的预测<sup>[18]</sup>。但是使用基于知识的方法需要依赖系统健康运行期间的大量处于不同状态的运行数据,缺乏足够多的数据将导致数据驱动模型的建模不准确甚至建模错误,最终导致故障诊断任务失败。

基于模型的故障诊断性能依赖于模型的精度,基于知识的方法高度依赖大量历史数据进行训练,存在高计算成本的缺点。为解决上述问题,提出了将上述故障诊断方法集成或组合方法,这就是所谓的混合故障诊断方法<sup>[13]</sup>。葛哲学<sup>[19]</sup>等提出对动态系统多源异类信息的案例表达方法,为复杂动态系统的故障诊断提供了一种有效的新途径,但是仍然需要对于大量历史案例的分析,工作量大;龚学兵<sup>[20]</sup>等人提出一种基于数据关联性分析的归纳式系统异常监测(IMS)方法,该方法能够建立卫星飞轮闭环系统的族类知识库,并可以根据云模型提供的定性知识有效判断系统的异常程度,但是不提供研究对象的故障程度的定量检测结果。目前研究较多的混合方法均将神经网络当作解析模型中个别参数的估计器来使用<sup>[21-22]</sup>,这样的诊断框架成立的前提是已知解析模型中未能准确建模的参数,且其余系统动力学已经得到准确建模。但是在工程实际中,往往不能得到原系统所有准确的建模参数甚至会有些参数未能进行建模,在这种情况下就不能使用该类参数估计的混合方法。

为解决上述问题,提出了将解析模型与数据驱动模型相串联的混合模型,取长补短,既可以使混合模型具有明确的物理意义,又可以在一定程度上提升模型的建模精度,使混合模型可以在局部和全局对原系统进行逼近,最终提升系统故障诊断性能。

## 2 对象模型及问题的提出

### 2.1 高精度飞轮模型

本文使用由 Goosdrich 公司研制生产的 ITHACO-A 型反作用飞轮作为研究对象<sup>[23]</sup>。该飞轮的功能框图如图 1 所示,主要包含 EMF 扭矩极限,速度极限,电机扰动,轴承扰动及摩擦扰动 4 个环路。

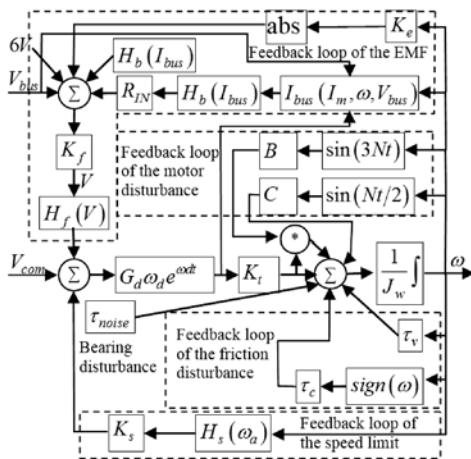


图 1 ITHACO-A 反作用飞轮模型  
Fig. 1 ITHACO-A reaction flywheel model

其中:  $V_{bus}$  为母线电压,  $K_e$  为电机反馈 EMF 参数,  $I_{bus}$  为母线电流,  $R_{IN}$  为电机驱动输入阻抗,  $B$  为电机转矩振动系数,  $C$  为电机转矩文波系数,  $N$  为电机磁极数,  $K_t$  为电机扭矩参数,  $G_d$  为反作用飞轮驱动增益,  $\omega_d$  为压流转换频率,  $\tau_{noise}$  为轴承扰动力矩,  $\tau_v$  为最终输出的力矩,  $\tau_c$  为库伦摩擦力系数,  $\tau_v$  为黏性摩擦力矩映射函数,  $K_s$  为超速

循环增益,  $K_f$  为电压反馈增益,  $I_m$  为电机电枢电流,  $\omega_s = \omega_s - |\omega|$  为转速极限差,  $\omega_s$  为转速极限,  $J_w$  为飞轮转动惯量,  $H_t, H_s, H_b$  为 Heaviside 函数。

由图 1 可知, 电机驱动器其实是一个增益为  $G_d$  的电压受控的电流源, 电机具有扭矩常数增益  $K_t$ , 成比例地传送扭矩给电流驱动器。飞轮模型是一个由不连续函数组成的非线性动态系统。其中电机电流与母线电流之间存在强非线性关系:

$$I_{bus} = \left[ \frac{1}{V_{bus} - 1} \right] (I_m^2 R_B + 0.04 |I_m| V_{bus} + P_q + \omega I_m K_e), \quad (1)$$

式中:  $I_{bus}$  为母线电流;  $V_{bus}$  为母线电压;  $I_m$  为电机的电枢电流;  $\omega$  为飞轮转速;  $k_e$  为反向 EMF 电压增益;  $R_B$  为电桥电阻;  $P_q$  为静态功率。

考虑温度以及飞轮角速度之间的双线性关系, 黏性摩擦产生负扭矩由下式给出:

$$\tau_v = [0.0049 - 0.00002(T + 30)], \quad (2)$$

式中  $T$  为轴承温度。

SOBHANI-TEHRANI<sup>[21]</sup> 等人将上述飞轮模型描述为:

$$\begin{aligned} \dot{I}_m &= G_d \omega_d [f_3(I_m, \omega) - f_5(\omega) + V_{com}] - \omega_d I_m, \\ \dot{\omega} &= \frac{1}{J} [f_1(\omega) + K_t I_m (f_2(\omega) + 1) - \tau_c f_4(\omega) - \tau_v \omega + \tau_{noise}], \end{aligned} \quad (3)$$

其中:

$$\begin{cases} f_1(\omega) = C \sin\left(\frac{\omega N t}{2}\right) \\ f_2(\omega) = B \sin(3 \omega N t) \\ f_3(\omega, I_m, V_{bus}) = H_f(V) V(\omega, I_m, V_{bus}) \\ f_4 = \text{sign}(\omega) \\ f_5(\omega) = K_s H_s(\omega_a) \\ V(\omega, I_m, V_{bus}) = K_f [V_{bus} - 6 - \text{abs}(\omega) K_e - (1 + R_{IN} I_{bus}) H_b(I_{bus})] \end{cases}, \quad (4)$$

式中各符号与图 1 所示飞轮模型中符号相对应。

由式(3)与式(4)可知该飞轮系统是一个复杂的动态非线性系统。由母线电流与黏性摩擦造成的非线性问题在实际建模中难以设定准确的参数。另外, 由于系统存在强的动态性, 所以建模时需要考虑动态系统中各状态量之间的相互关系, 以及系统外部存在的不确定性干扰对系统故障诊断所造成的影响。

### 2.2 在轨飞轮故障诊断问题的提出

实际工程中, 多数实际系统故障是系统状态

和输入的非线性函数, 在采用传统线性方程对这类非线性系统进行研究时, 最常采用的手段是在某些工作点附近进行线性化, 但是, 这样难以对系统进行全面的故障分析, 同时引入了线性化误差。因此许多学者提出了针对非线性系统更一般的数学描述。选取飞轮电枢电流以及转速作为系统状态量  $x = [I_m; \omega]$ , 控制电压作为系统输入  $u = V_{com}$ , 系统输出  $y = x$ , 式(3)可表述为:

$$\dot{\mathbf{x}} = \begin{bmatrix} \dot{I}_m \\ \dot{\omega} \end{bmatrix} = \begin{bmatrix} G_d \omega_d [f_3(I_m, \omega) - f_5(\omega) + V_{com}] - \omega_d I_m \\ \frac{1}{J} K_t I_m \end{bmatrix} + \begin{bmatrix} 0 \\ f_1(\omega) + K_t I_m f_2(\omega) - \tau_c f_4(\omega) - \tau_v \omega + \tau_{noise} \end{bmatrix} = \mathbf{g}(\mathbf{x}, \mathbf{u}) + \boldsymbol{\phi}(\mathbf{x}), \quad (5)$$

式中:  $\mathbf{g}(\mathbf{x}, \mathbf{u})$  表示系统状态更新非线性函数,  $\boldsymbol{\phi}(\mathbf{x})$  为系统干扰函数。使用欧拉后向差分模型进行离散化可以得到系统状态方程的离散表达式, 具体差分方程详见第4节, 此处使用非线性函数进行描述如下:

$$\mathbf{x}_{k+1} = f(\mathbf{x}_k, \mathbf{u}_k) + \boldsymbol{\sigma}_k, \quad (6)$$

式中:  $\mathbf{x}_k \in \mathbf{R}^n$  为第  $k$  个样本下系统状态矢量;  $\mathbf{u}_k \in \mathbf{R}^r$  为第  $k$  个样本下控制输入量;  $f: \mathbf{R}^n \times \mathbf{R}^r \rightarrow \mathbf{R}^n$  为离散框架下系统状态更新函数;  $\boldsymbol{\sigma}_k \in \mathbf{R}^n$  为第  $k$  个样本下系统干扰。值得注意的是式(5)中系统干扰函数  $\boldsymbol{\phi}(\mathbf{x})$  在离散框架下由  $\boldsymbol{\sigma}_k$  表示, 此时干扰与系统状态无关, 这显然与实际情况不符, 但是使用混合框架对系统进行建模的时候可以忽略该问题, 因为混合框架中的神经网络部分除了对建模误差进行修正外, 同时也建立了系统状态与干扰之间的映射关系, 可以对系统干扰进行建模修正。

为了对系统故障进行描述, 引入故障函数  $\varphi(\mathbf{x}_k, \mathbf{u}_k)$ , 该函数表征系统发生故障时对系统状态的影响<sup>[21]</sup>。由此在离散框架下对飞轮系统进行相应描述如式(7)所示:

$$\begin{cases} \mathbf{x}_{k+1} = f(\mathbf{x}_k, \mathbf{u}_k) + \varphi(\mathbf{x}_k, \mathbf{u}_k) + \boldsymbol{\sigma}_k, \\ \mathbf{y}_k = \mathbf{x}_k + \mathbf{v}_k \end{cases}, \quad (7)$$

式中:  $\mathbf{v}_k \in \mathbf{R}^n$  表示第  $k$  个样本下系统测量噪声;  $\varphi: \mathbf{R}^n \times \mathbf{R}^r \rightarrow \mathbf{R}^n$  表示系统故障函数, 该函数在无故障运行时为 0, 系统出现故障的时候表现出故障特性, 该函数不可测; 其余变量与式(6)中相同。

进行该系统进行故障诊断的目的是当系统发生故障时(故障函数  $\varphi$  不为零时), 对系统故障函数  $\varphi$  做出准确的估计。进行系统故障诊断的模型如式(8)所示:

$$\begin{cases} \hat{\mathbf{x}}_{k+1} = \hat{f}(\mathbf{x}_k, \mathbf{u}_k) + \varphi(\mathbf{x}_k, \mathbf{u}_k), \\ \hat{\mathbf{y}}_k = \mathbf{x}_k \end{cases}, \quad (8)$$

式中:  $\hat{\mathbf{x}}_k \in \mathbf{R}^n$  为第  $k$  个样本下系统状态矢量的估计量;  $\mathbf{u}_k \in \mathbf{R}^r$  为第  $k$  个样本下控制输入量;  $\hat{f}: \mathbf{R}^n \times \mathbf{R}^r \rightarrow \mathbf{R}^n$  为系统行为函数模型; 其余符号与式

(7)中相同。

有效的系统故障诊断需要两个必要前提: 对系统的标称行为的建模要准确, 即  $\hat{f}(\cdot)$  要足够逼近实际系统行为函数  $f(\cdot)$ ; 对系统行为函数的建模要具有一定鲁棒性, 即当存在系统干扰时系统模型  $\hat{f}(\cdot)$  同样要在一定程度上逼近实际系统行为函数  $f(\cdot)$ 。

在轨飞轮是一个复杂的非线性系统, 单一的数学解析模型不够精确, 进而直接影响诊断可靠性以及诊断准确性。而单独应用神经网络模型进行故障诊断时, 网络动态性能难以达到原系统的动态范围, 另外也存在训练数据不足的问题。基于以上问题, 提出了基于神经网络混合模型的故障诊断方法。

### 3 基于神经网络混合模型的故障诊断

#### 3.1 基于神经网络混合模型的故障诊断框架

将系统输出检测值与模型输出估计值作差产生的残差作为故障检测判断标准:

$$\boldsymbol{\delta}_k = \mathbf{y}_k - \hat{\mathbf{y}}_k. \quad (9)$$

理想状态下, 当系统无故障时, 该残差  $\boldsymbol{\delta}$  为 0, 而当该残差值大于设定故障阈值的时候即判定系统出现故障。但是该残差同时包含了系统建模误差与系统干扰, 这也是影响故障诊断准确性的主要原因。

由于单一的数学解析模型不够精确, 进而直接影响诊断可靠性以及诊断准确性。而单独应用神经网络模型进行故障诊断时, 网络动态性能难以达到原系统的动态范围, 另外也存在训练数据不足的问题, 导致单一的神经网络模型无法保证结果收敛。为了解决上述问题, 提出了使用神经网络模型与数学解析模型进行串联建立混合模型, 并分析了该混合模型诊断原理以及对诊断鲁棒性的影响。该诊断方法框架如图2所示。

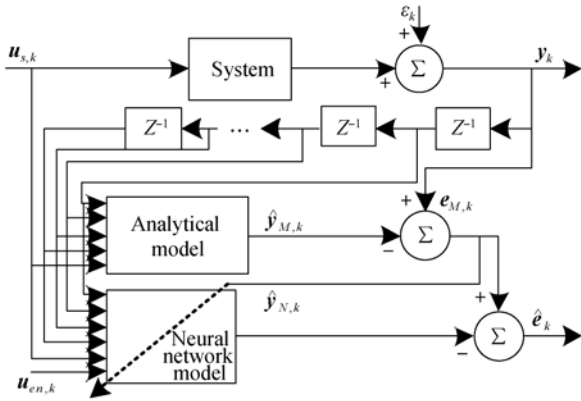


图 2 基于神经网络混合模型的故障诊断框架

Fig. 2 Fault diagnosis framework based on neural network hybrid model

图 2 所示的故障诊断框架将连续系统做了离散处理,其中  $u_{s,k}$  表示  $k$  时刻的系统输入变量;  $u_{en,k}$  表示  $k$  时刻的系统环境变量输入;  $y_k$  表示  $k$  时刻系统输出;  $e_k$  表示  $k$  时刻外部干扰;解析模型表示所建数学解析模型函数  $f_m$ ,  $k$  时刻该模型输出为  $\hat{y}_M$ ;  $e_{M,k}$  表示解析模型与系统输出之间的误差,本文将其称作一级残差;神经网络模型表示神经网络模型函数  $f_n$ ,该模型输出为  $\hat{y}_N$ ,表示神经网络模型对数学解析模型的补偿量,本文将其称作残差补偿;  $\hat{e}_k$  表示混合模型最终的残差输出,该值表示系统模型函数  $\hat{f}$  与实际系统函数  $f$  之间的差值,本文将其称作二级残差。神经网络训练阶段,训练目标是通过选用合适的神经网络以及网络训练方法使得二级残差尽量小,最终使得诊断模型足够的逼近原系统。使用经过训练的神经网络参与系统故障诊断时,最终二级残差  $\hat{e}_k$  的值反映系统的故障情况。

下面从原理上证明该方法的有效性。

非线性系统中的动力学函数无法精确建模,但是可以通过使用多项式逼近得到,该结论由第一 Weierstrass 逼近定理得出:任意定义在有界区间  $[a, b]$  的连续函数  $f(x)$ ,总是可以用多项式  $P_n(x)$  来逼近,两者之间的误差可表示为:

$$E_n(f) = \max_{a \leq x \leq b} |f(x) - P_n(x)| = \|f - P_n\|_\infty, \quad (10)$$

当  $n \rightarrow \infty$  时,误差趋近于 0。

由此式(7)中非线性函数  $f(\mathbf{x}_k, \mathbf{u}_k)$  可由多项式表示为:

$$f(\mathbf{x}_k, \mathbf{u}_k) \approx P(\mathbf{x}_k, \mathbf{u}_k) = \sum_{i=0}^n \binom{n}{i} \mathbf{x}_k^i \mathbf{u}_k^n, \quad (11)$$

其中  $\binom{n}{i}$  表示  $n$  阶二项式系数。式(7)所示系统可表示为:

$$\begin{aligned} \mathbf{y}_k &= \mathbf{x}_k + \mathbf{v}_k = \\ & f(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}) + \varphi(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}) + \sigma_k + \mathbf{v}_k = \\ & P_n(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}) + \varphi(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}) + \boldsymbol{\varepsilon}_k, \end{aligned} \quad (12)$$

式中:  $y_k$  为系统输出;  $P_n(\mathbf{x}_{k-1}, \mathbf{u}_{k-1})$  为逼近系统动力学非线性函数的多项式;  $\boldsymbol{\varepsilon}_k$  为包含系统扰动与测量噪声的干扰量。为后续描述方便,设  $\mathbf{r}_k = [\mathbf{x}_k^0 \mathbf{u}_k^0 \quad \mathbf{x}_k^1 \mathbf{u}_k^{n-1} \quad \cdots \quad \mathbf{x}_k^n \mathbf{u}_k^0]^T$ , 则待诊断的系统可由下式描述:

$$\mathbf{y}_k = \mathbf{r}_{k-1}^T \mathbf{p} + \varphi(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}) + \boldsymbol{\varepsilon}_k, \quad (13)$$

式中  $\mathbf{p}$  为多项式各项参数。

文献[24]使用 Weierstrass 定理证明了两层网络与足够数量的隐层节点可以逼近任意连续函数,针对不同复杂程度的非线性系统,结果逼近精度依赖于隐层节点数量以及训练所用数据量。所以可以利用神经网络对其系统误差进行补偿。采用神经网络对系统误差函数进行拟合逼近可以降低对网络规模以及训练数据的要求。假设需要拟合的原系统可以使用多项式进行描述:

$$\begin{aligned} y &= a_0 + a_1 u + a_2 u^2 + \cdots + a_n u^n + \varepsilon \\ y_M &= a_{m0} + a_{m1} u + a_{m2} u^2 + \cdots + a_{mh} u^h \\ y_\Delta &= y - y_M = \\ & (a_0 - a_{m0}) + (a_1 - a_{m1}) u + \cdots + \\ & (a_h - a_{mh}) u^h + a_{mh+1} u^{h+1} + \cdots + a_n u^n + \varepsilon = \\ & a_{\Delta 0} + a_{\Delta 1} u + \cdots + a_{\Delta h} u^h + \cdots + a_n u^n + \varepsilon, \end{aligned} \quad (14)$$

式中:  $u$  表示系统动态行为的驱动变量;  $a_i, a_{mi}, a_{\Delta i}$  分别表示原系统各项参数、解析模型各项参数以及误差函数各项参数;  $y$  表示原系统函数;  $y_M$  表示建立的解析模型;  $y_\Delta$  表示建模误差。  $\varepsilon$  表示外界扰动。

由于  $y_M$  在一定程度上反映原系统  $y$  的行为,反映在各项系数上则有  $|a_{\Delta i}| < |a_i|$ , 其中  $(i = 0, 1, \cdots, n), i \in N_i$ 。针对一些已知的参数  $a_{\Delta j} = 0, j \in N_j$ , 或者可以精确建模的参数有  $a_{\Delta k} \approx 0, k \in N_k$ 。此时式(14)中  $y_\Delta$  可以得到简化:

$$y_\Delta = \varepsilon + \sum_l a_{\Delta l} u^l + \sum_{s=1}^{n-h} a_{h+s} u^{h+s}, \quad (15)$$

其中:  $l \in N_i - (N_j \cup N_k)$ 。此时的误差函数与原系统函数相比,由于项数的减少降低了系统动态

复杂性,降低了对神经网络建模的要求。最终神经网络的建模对象由原系统变为了  $y_{\Delta}$ 。经过建模得到神经网络模型  $y_N$ :

$$y_N \approx y_{\Delta}. \quad (16)$$

该神经网络模型包含了对系统扰动  $\epsilon$  的建模,所以得到的神经网络模型对系统扰动存在一定鲁棒性。使用该方法对系统行为函数进行建模得到如下所述结果:

$$\hat{y}_k = y_M + y_N. \quad (17)$$

此时原系统可表述为:

$$y = \hat{y} + \vartheta = y_M + y_N + \vartheta, \quad (18)$$

式中  $\vartheta$  表示混合模型的建模误差以及系统扰动的叠加误差。由于使用神经网络模型对原解析模型进行了建模误差补偿,同时使用包含系统干扰的数据进行网络训练使得神经网络模型环境干扰进行了学习建模,最终得到满足故障诊断的系统混合模型。

在混合诊断框架中,使用数学解析模型模拟系统动态行为,该解析模型输出  $y_{M,k}$  可以动态的跟踪原系统的动态输出  $y_k$ ,且具有较好的动态性能。但该解析模型与原系统相比存在一定的建模误差。神经网络模型作为对数学解析模型的补充,可以减小建模误差,在解析模型的基础上,神经网络模型可以自适应的学习该系统所处的环境信息,使得诊断系统具有一定的鲁棒性能。

### 3.2 混合模型对系统故障诊断鲁棒性的影响分析

在基于模型的故障诊断框架中,由式(9)可知系统残差为系统输出检测值与模型输出之间的差值,用于故障诊断中时,该残差中包含建模误差、系统干扰以及故障响应3个分量,如式(19)所示:

$$\delta_k = y_k - \hat{y}_k = \Delta_m + \epsilon + \varphi_f, \quad (19)$$

其中: $\Delta_m$  表示模型建模误差; $\epsilon$  表示系统干扰; $\varphi_f$  表示故障函数。理想状态下  $\Delta_m \approx 0$  且系统干扰假设为幅值极小的零均值白噪声,满足式(20):

$$\begin{cases} E(\epsilon) = 0 \\ \text{cov}(\epsilon) = \sigma^2 \end{cases}. \quad (20)$$

在满足上述假设的前提下,当系统无故障时,系统故障函数  $\varphi_f$  接近于零。当出现故障时,  $|\delta_k|$  大于提前设定的故障阈值  $\xi_h$ , 即  $|\varphi_f| > 0$ 。

但在实际应用过程中,系统建模误差无法避免,尤其是在对复杂非线性系统进行建模的过程中。系统干扰也往往并不满足零均值白噪声的假设。这时候残差不能反映真实的系统故障信息,

将导致虚警甚至漏警。所以需要系统建模误差以及系统噪声进行补偿处理。神经网络具有良好的非线性拟合能力,适合对解析模型存在的误差进行补偿,并对无法准确建模的系统干扰进行学习建模。

混合故障诊断模型与原系统输出检测值生成的新的残差  $\zeta$ :

$$\zeta = y - \hat{y} = y - y_M - y_N = \vartheta, \quad (21)$$

式中各变量表达意义与2.1节相同。采用多层前馈神经网络与数学解析模型构成混合模型,其中神经网络模型的输入由原系统输入  $r_{s,k}$ , 经过延迟的系统输出  $r_{y,k} = [y_{k-1} \ y_{k-2} \ \dots \ y_{k-p}]$  以及环境检测输入  $r_{en,k}$  构成:  $r_{net,k} = [r_{s,k} \ r_{y,k} \ r_{en,k}]$ 。用于神经网络训练的输出使用包含系统干扰的一级残差  $e_{M,k}$ 。由于该神经网络输入中包含带延迟抽头的输出数据所以网络具有动态性能,并且该网络输入包含了环境检测信息,所以可以使得混合模型对环境信息进行学习,进一步增强混合模型对环境干扰的鲁棒性。

### 3.3 混合模型系统辨识算例

为了验证使用混合模型进行鲁棒故障诊断的有效性,假设对如下动态非线性系统进行故障诊断:

$$y_k = \frac{p_1 \sin(u_{1,k}^2) + p_2 u_{2,k} + p_3 u_{1,k} u_{2,k} + \epsilon_k}{p_4 y_{k-1}}, \quad (22)$$

其中:真实系统参数取  $p = [1.5 \ 0.5 \ 0.2 \ 2]$ ; 输入变量  $u_k = [u_{1,k} \ u_{2,k}]$  以及系统干扰噪声  $\epsilon_k$  ( $k=1, 2, \dots, n$ ), 符合均匀分布:  $u_k \in U(0, 2)$  以及  $\epsilon_k \in U(-0.05, 0.1)$ , 其中  $U(\cdot)$  表示均匀分布。因此系统干扰不满足式(20)中均值假设。为了比较单独解析模型、单独神经网络模型以及混合模型对原系统的辨识能力,分别建立3种模型。

假设解析模型存在建模误差,所建系统解析模型中缺少参数  $p_3$  对应动态响应并且存在参数建模不准确,所建解析模型如下:

$$y_{m,k} = \frac{p_{m1} \sin(u_{1,k}^2) + p_{m2} u_{2,k}}{p_{m4} y_{k-1}}, \quad (23)$$

式中解析模型参数只有3个,各参数取值为  $p_m = [p_{m1} \ p_{m2} \ p_{m4}] = [1.3 \ 0.5 \ 3]$ 。采用多层前馈神经网络进行系统辨识,隐层神经元个数设置为10个,采用 sigmoid 函数作为激活函数,利用梯度下降法对网络进行训练。训练数据为

$\{(r_k, y_k)\}_{k=1}^{n=300}$ , 其中  $r_k = [u_{1,k} \ u_{2,k} \ y_{k-1}]$ ; 为便于比较, 混合模型中神经网络结构设置与单神经网络模型相同, 训练数据选取  $\{(r_k, e_{m,k})\}_{k=1}^{n=300}$ , 其中  $e_{m,k} = y_k - y_{m,k}$ 。为后续进行故障诊断, 需要使用真实无故障系统输出与该 3 种模型输出分别进行比较。真实无干扰系统输出与 3 种不同模型输出之间的误差均值、方差以及最大误差值如表 1 所示, 由该表可知混合模型与单模型相比误差的方差以及最大误差值均大幅减小, 误差均值没有明显改善。对存在建模误差以及系统干扰系统进行鲁棒故障诊断时对误差均值无要求, 鲁棒性主要体现在误差方差上, 所以混合模型可以有效进行鲁棒故障诊断。各模型误差曲线如图 3 所示。

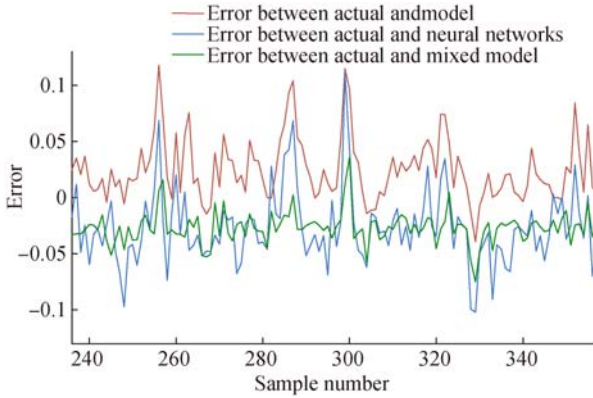


图 3 3 种诊断模型误差曲线

Fig. 3 Error curves come of three kinds of diagnostic models

表 1 3 种诊断模型误差评价

Tab. 1 Error evaluation of three diagnostic models

类型	均值	方差	最大误差
单解析模型	0.020 907	0.000 841	0.152 377
单神经网络	-0.025 348	0.001 030	0.165 412
混合模型	-0.026 675	0.000 195	0.088 053

#### 4 在轨飞轮故障诊断混合模型

将第 2 节提到的飞轮模型作为研究对象, 针对该系统进行故障诊断。考虑建模误差对故障诊断带来影响时, 假设该系统中总线电流以及黏性

摩擦的映射关系假设难以精确建模, 并且系统参数部分建模不准确, 按照采样时间  $T_s = 50 \text{ ms}$ , 使用差分方程表示系统模型如下式所示:

$$\begin{cases} I_M(k+1) = (1 - \omega_{Md}) I(k) + (V_{M1}(k) - V_{M2}(k) \\ + V_{com}) \omega_{Md} G_{Md} \\ T_M(k) = K_{Mt} I_M(k) - T_{Mv}(k) - T_{Mc}(k) \\ \omega_M(k+1) = \omega_M(k) + \frac{1}{J_{Mw}} T_M(k) \end{cases}, \quad (24)$$

其中:

$$\begin{aligned} V_{Mm}(k) &= K_{Mf} [V_{Mbus} - 10 - \\ &H_{Mb} (1 + R_{Min} I_{Mbus}(k)) - K_{Me} |\omega_M(k)|], \\ I_{Mbus}(k) &= \frac{1}{V_{Mbus}} (I_M^2(k) R_{Mb} + K_{Me} I_M(k) \omega_M(k)), \\ V_{M1}(k) &= H_{Mf} V_{Mm}(k), \\ V_{M2}(k) &= H_{Ms} K_{Ms} |\omega_{Ms} - \omega_M(k)|, \\ T_{Mv}(k) &= H_{Md} \frac{(0.06 - 0.000 23 \times T_{tem})}{1 000} \omega_M(k), \\ T_{Mc}(k) &= K_c \omega_M(k), \end{aligned}$$

式中:  $I_M(k)$ 、 $\omega_M(k)$  分别为  $k$  时刻电枢电流以及飞轮转速;  $\omega_{Md}$  为压流转换频率;  $V_{M1}$  为 EMF 回路反馈电压;  $V_{M2}$  为速度限制环路反馈电压;  $V_{com}$  为控制器生成的控制电压;  $G_{Md}$  为反作用飞轮的驱动增益;  $J_M$  为飞轮转动惯量;  $K_{Mt}$  为电机扭矩增益;  $T_{Mc}$  为库伦摩擦力矩;  $T_{Mv}$  为黏性摩擦力矩;  $K_{Mf}$  为电压反馈增益;  $V_{Mm}$  为 EMF 反馈电压;  $V_{Mbus}$  为母线电压;  $I_{Mbus}$  为母线电流;  $R_{Min}$  为电机驱动输入阻抗;  $K_{Me}$  为电机反馈 EMF 参数;  $R_{Mb}$  为驱动器电桥电阻;  $K_{Ms}$  为超速循环增益;  $\omega_{Ms}$  为转速极限;  $T_{tem}$  为当前电机温度;  $K_{Mc}$  为库伦摩擦系数;  $H_{Mf}$ ,  $H_{Ms}$ ,  $H_{Mb}$ ,  $H_{Md}$  为取值分别如下:

$$\begin{aligned} H_{Mf} &= \begin{cases} 0, V_{Mm} > 0 \\ 1, V_{Mm} < 0 \end{cases}, \\ H_{Ms} &= \begin{cases} 0, \omega_{Ms} > |\omega_M| \\ 1, \omega_{Ms} < |\omega_M| \end{cases}, \\ H_{Mb} &= \begin{cases} 0, I_{Mbus} < 0 \\ 1, I_{Mbus} > 0 \end{cases}, \\ H_{Md} &= \begin{cases} 1, \omega_M > 0 \\ 0, \omega_M = 0 \\ -1, \omega_M < 0 \end{cases}. \end{aligned} \quad (25)$$

对飞轮建立解析模型如上式所示, 其中各参数取值如表 2 所示:

表 2 模型中的常量

Tab. 2 Math model constants

Parameter	Units	Value	Parameter	Units	Value
$K_{Me}$	V/(rad/sec)	0.029	$G_{Md}$	A/V	0.19
$K_{Mt}$	N·m/A	0.04	$\omega_{Md}$	rad/sec	0.9
$K_{Mf}$	1	0.5	$\omega_{Ms}$	rad/sec	690
$K_{Ms}$	V/(rad/sec)	95	$R_{Min}$	$\Omega$	2
$K_{Mc}$	N·m	0.004	$R_{Mb}$	$\Omega$	2
$J_M$	Kg·m <sup>2</sup>	0.097	$V_{Mbus}$	V	24

采用文献[23]中描述的精确飞轮模型作为原系统,将上述解析模型与原系统运行于相同的控制输入下进行对比.设输入为:

$$V_{Mcom}(t) = 3\sin(t) + 2\cos(4t) + \lambda(t), \quad (26)$$


式中: $V_{com}(t)$ 为控制电压; $\lambda(t)$ 为采样范围在 $[-0.5, 0.5]$ 之间均匀分布的随机过程.

由于离散解析模型在结构以及参数上与原系统存在一定误差,所以输出力矩存在差异.在对系统进行故障检测时,上述差异是不能容忍的.为此提出使用神经网络进行辅助建模的混合方法,这里建立一个包含三层前馈神经网络的混合模型.

混合模型中网络输入为一个长度为 5 的向量  $\mathbf{x}(k) = [V_{com}(k) \quad T_{tem}(k) \quad \omega(k) \quad I(k) \quad T(k)]^T$ , 网络输出为输出力矩残差估计值  $\Delta\hat{T}$ , 训练使用飞轮输出力矩的一级残差  $\Delta T(k) = T(k) - T_M(k)$ . 训练数据采用同一控制电压在不同转速的初始条件下生成.初始转速取值为 $[-400, -350, \dots, 400]$ ,即在 $-400 \sim 400$  rad/s 之间每隔 50 rad/s 生成一次训练数据.


建立基于神经网络的混合模型主要是为了克服单独解析模型建模不准确的问题,与单独神经网络模型由于训练数据匮乏以及网络结构不确定性引起的建模不准确问题.为了对比该混合模型与的建模优势,使用同样的神经网络结构与训练数据进行了单独的神经网络建模进行比较.

对解析模型所描述的离散系统设仿真步长为 0.01 s. 初始电枢电流为 0 A, 分别取初始转速为 200 rad/s 与 -550 rad/s. 分别得到了如图 4 所示的力矩输出曲线与误差曲线:



(a) 初始转速为 200 rad/s

(a) Initial speed is 200 rad/s



(b) 初始转速 -550 rad/s

(b) Initial speed is -550 rad/s

图 4 不同初始转速下各诊断模型输出力矩误差结果对比  
Fig. 4 Comparison of output torque errors of different diagnostic models under different initial speed

当初始转速为 200 rad/s 时,不同模型力矩输出误差如图 4(a)所示,该情形下存在飞轮转速的过零的情况.由于飞轮系统存在非线性,使得力矩输出在转速零点附近发生了非线性跳变,其中混合模型可以较好地跟踪飞轮系统实际动态行为,解析模型也可以对实际系统行为进行跟踪,但是存在较大的偏差,单神经网络模型在转速零点附近的动态跟踪性能较差,在低转速情况下静态误差相差不大.

当初始转速为 -450 rad/s 时,不同模型力矩输出误差如图 4(b)所示,该情形下飞轮转速由初始较高转速向较低转速过渡.混合模型可以较好地跟踪飞轮系统实际动态行为;随着飞轮转速的改变解析模型一直存在较大跟踪误差;单神经网络模型与混合模型相比在较大转速情况下跟踪误差较大随着转速减小,跟踪误差逐渐减小.

由上述分析可知,混合模型与解析模型相比可以大大减小静态跟踪误差,与单独神经网络模型相比可以提升动态跟踪性能.

## 5 故障诊断仿真验证

本节分别对存在母线电压故障以及电枢电流故障的飞轮使用上述混合诊断框架进行了仿真验证。分别对飞轮系统注入母线电压以及电枢电流故障,随后应用混合故障诊断框架对存在故障的飞轮进行故障诊断。需要注意的是,本节仿真的前提是飞轮控制电压、电枢电流以及转速是可测的,而在飞轮的实际工作中上述前提也是成立的。

### 5.1 飞轮故障注入

飞轮工作回路中,对电流影响较大的是 EMF 回路,该回路存在较强的非线性映射,所以对其进行故障特性研究具有一定代表性。对飞轮系统注入时变的母线电压故障,模拟电源电压瞬时的下降的变化:

$$V_{bus}(t) = \begin{cases} V_{bus}^{nom}, & 0 \leq t < 5 \\ V_{bus}^{nom} - 6, & 5 \leq t < 10 \\ V_{bus}^{nom} - 9, & 10 \leq t < 15 \\ V_{bus}^{nom} - 12, & 15 \leq t < 20 \\ V_{bus}^{nom} - 6, & 20 \leq t < 25 \\ V_{bus}^{nom}, & 25 \leq t < 30 \end{cases}, \quad (27)$$


式中:  $V_{bus}^{nom} = 24 \text{ V}$  为正常母线电压;  $V_{bus}$  为注入故障后的母线电压,该值在 5~25 s 发生瞬时的异常故障。

在轨飞轮的力矩输出是整个飞轮系统的核心功能,电机电流故障会直接影响飞轮的力矩输出。将间歇时变的电机电流故障注入到飞轮系统。其中电机电枢电流故障可以体现在电机扭矩增益  $K_t$  的改变上。下面将电机扭矩增益  $K_t$  的故障以正弦变化的形式注入到反作用飞轮上:

$$K_t(t) = \begin{cases} K_t^{nom}, & 0 \leq t < 10 \\ K_t^{nom} - 0.02 \sin\left[\frac{2\pi(t-10)}{10}\right], & 10 \leq t \leq 20, \\ K_t^{nom}, & 20 < t \leq 30 \end{cases} \quad (28)$$


式中:  $K_t^{nom} = 0.029$  为电机扭矩增益的标准值,  $K_t$  为注入故障以后的点击扭矩增益值,该值在 10~20 s 发生异常故障。

假设该飞轮全状态可测,采用式(26)中控制电压,飞轮初始转速设置为 350 rad/s,分别对飞轮注入上述故障,该过程中飞轮转速会逐渐降低,其结果如图 5 所示:



(a) 母线电压故障

(a) Voltage fault



(b) 电流故障

(b) Current fault

图 5 注入母线电压以及电流故障后输出结果对比

Fig. 5 Comparison of output results after injection of bus voltage and current fault

图 5 为分别注入电流故障与母线电压故障后测得电流、力矩与正常系统的对比结果。如图 5(a)所示,由于转速不同所以该故障对电流造成的影响也不相同:当飞轮处于高转速时,轻微的母线电压故障会使 EMF 电压变为负值,此时母线电压故障会对电流产生较大影响;当飞轮转速较低时,轻微的母线电压故障不足以使 EMF 电压变为负值,此时母线电压故障不会对飞轮电流以及输出力矩产生影响。由图 5(b)可知电流故障会直接影响飞轮力矩输出,输出力矩受到电流故障的影响会随故障程度增大而增大。

### 5.2 基于混合模型的故障诊断

针对 5.1 节提到的存在故障的飞轮系统,采用混合模型进行故障诊断,通过对比诊断结果说明混合模型的优势。诊断模型需要在系统发生故障时保持原无故障系统的动态特性,诊断模型输出值与实际故障系统测量值的差作为故障判断的依据,其中图 6、图 7 分别展示了在不同转速下故障检测结果。为进一步体现混合模型的性能,将发生故障时各模型的估计结果与未发生

故障系统进行比较,其差值体现模型的跟踪原系统的能力,表 3、表 4 分别展示了不同模型在不同转速下跟踪原系统的性能。

当飞轮系统存在母线电压故障时,混合模型、单独解析模型和单独神经网络模型对电流的故障检测结果如图 6 所示。图 6(a)为初始转速较高设置为 400 rad/s 时电流故障检测结果,图 6(b)为初始转速较低设置为 50 rad/s 时的检测结果。可知,高转速情况下,混合模型可以检测出较为严重的母线电压故障。而在低转速情况下,母线电压故障难以得到有效检测。在两种初始转速情形下,单独解析模型的故障检测误差趋向发散,导致故障诊断失败,而单独神经网络模型的故障检测在一定条件下存在偏差,将导致误警。混合模型故障检测表现良好,可以有效进行故障诊断。

对各模型的电流跟踪误差采用均值、方差以及跟踪误差最大值进行评价如表 3 所示。通过表 3 数据可知,混合模型与存在建模误差的解析模型以及单神经网络模型相比可以有效减小建模误差引起的静态偏差,跟踪过程平稳。

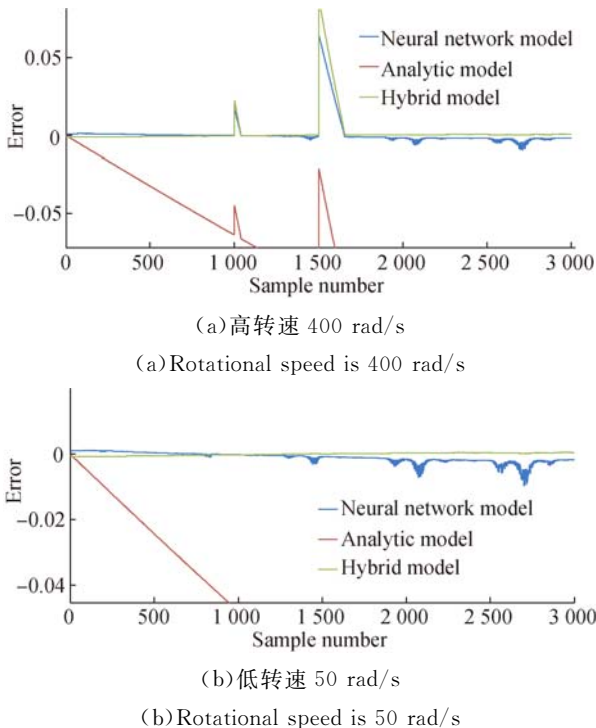


图 6 各模型在注入母线电压故障时不同转速下电流跟踪误差

Fig. 6 Current tracking error of each model under different rotating speed when the bus voltage fault is injected

表 3 注入母线电压故障不同转速下电流跟踪误差评价  
Tab. 3 Evaluation of current tracking error under different speed of injected bus voltage fault(A)

	高转速			低转速		
	均值	方差	最大误差	均值	方差	最大误差
单解析模型	0.320 1	0.035 3	0.612 1	0.331 9	0.034 0	0.616 1
单神经网络	-0.001 1	2.85e-06	0.001 2	-9.50e-04	2.20e-06	0.001 2
混合模型	-1.87e-04	9.56e-07	6.64e-04	9.96e-06	1.50e-07	6.55e-04

当飞轮系统存在电机电流故障时,混合模型、单独解析模型和单独神经网络模型对力矩的故障检测结果如图 7 所示。图 7(a)、图 7(b)分别为飞轮在初始转速 400 rad/s 以及初始转速为 50 rad/s 的情况下得到的检测结果。在发生故障的 10~20 s 时间区间内,高初始转速情况下解析模型存在较大的静态检测误差,单独神经网络模型检测结果不稳定,低初始转速情况下解析模型与单神经网络模型均存在较大的静态检测误差,而混合模型在两种转速情况下可以有效检测出飞轮力矩故障。

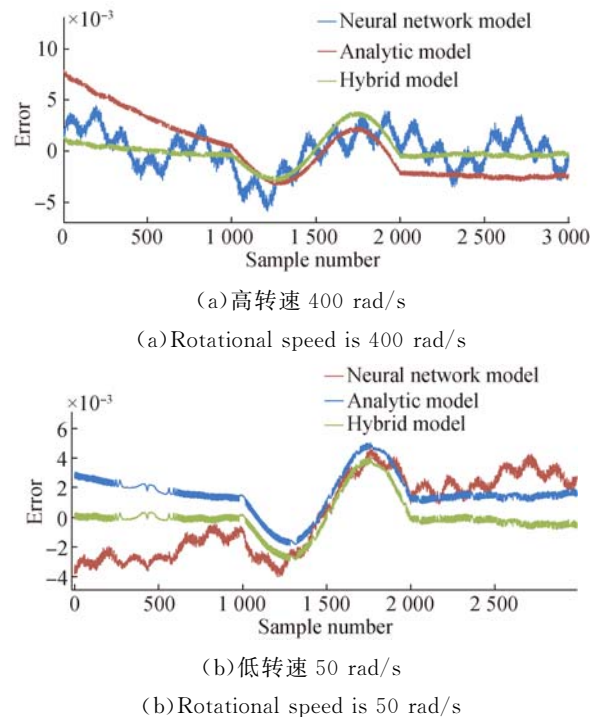


图 7 各模型在注入电流故障时不同转速下力矩跟踪误差

Fig. 7 Moment tracking error of each model under the condition of injected current fault at different speeds

对各模型的力矩跟踪误差评价如表 4 所示。通过表 3 数据可知,混合模型与存在建模误差的解析模型相比可以有效减小建模误差引起的静态偏差,跟踪过程平稳;与单神经网络模型相比,高转速情况下跟踪均值较大单方差小,可以平稳跟踪原系统,在低转速情况下可以有效减小静态跟踪偏差并实现平稳跟踪。

表 4 注入电流故障不同转速下力矩跟踪误差评价

Tab. 4 Evaluation of torque tracking error under different rotating speed of injection current (N·m)

	高转速			低转速		
	均值	方差	最大误差	均值	方差	最大误差
单解析模型	0.004 3	1.76e-06	0.008 0	0.001 5	2.53e-07	0.003 0
单神经网络模型	2.96e-05	2.77e-06	0.004 5	1.85e-04	4.74e-06	0.004 5
混合模型	-5.45e-04	2.59e-07	6.01e-04	-8.36e-05	4.61e-08	3.93e-04

上述母线电压及电机电流故障诊断仿真结果表明,基于混合模型的故障诊断方法与单独采用存在建模误差的解析模型方法以及单独的神经网络模型方法相比能够有效的对故障进行检测,并避免由于建模误差引起的故障检测虚警以及漏警现象。

## 6 结 论

基于混合模型的飞轮故障诊断方法由于使用

了神经网络对包含系统扰动的一级残差进行建模,所以最终所得的混合模型对系统扰动具有一定鲁棒性。混合方法与单解析模型方法相比有效提升了诊断模型的精度,避免由于建模误差引起的电流状态跟踪发散问题。力矩跟踪误差均值在高转速工况下降低了 87%,在低转速工况下降低了 44%,最大跟踪误差在两种工况下分别降低了 92%和 86%,说明该混合方法可以有效修正解析模型存在的建模误差问题。混合方法与单神经网络模型方法,电流跟踪误差均值在不同工况下分别降低了 83%和 98%,最大跟踪误差降低了 45%,力矩跟踪误差在高转速的情况下,由于单神经网络模型跟踪误差在零值附近波动所以均值较混合模型小,但混合模型的最大跟踪误差降低了 86%。转速工况下跟踪误差均值降低了 54%,最大误差降低了 91%,说明混合方法可以有效解决由于缺少训练数据而造成的神经网络模型建模不准确的问题。混合模型的误差跟踪方差与单解析模型以及单神经网络模型相比均有大幅下将,说明混合模型可以平稳地模拟原无故障系统运行状态,稳定的提供用于故障诊断的估计数据。在后续的研究中,需要对该混合方法的诊断误差精度做深入分析研究,同时混合模型中神经网络模型的结构以及性能优化也是一个值得深入研究的方向。

### 参考文献:

- [1] 韩宇. 执行器故障情况下的航天器姿态容错控制 [D]. 哈尔滨:哈尔滨工业大学, 2016: 2-5.  
HAN Y. *Spacecraft attitude fault-tolerant control methods with actuator fault* [D]. Haerbin: Harbin Institute of Technology, 2016: 2-5 (in Chinese).
- [2] GAO Z, CECATI C, DING S X. A survey of fault diagnosis and fault-tolerant techniques - part 1: Fault diagnosis with model-based and signal-based approaches[J]. *IEEE Transactions on Industrial Electronics*, 2015, 62(6): 3757-3767.
- [3] DING S X. *Model-based Fault Diagnosis Techniques: Design Schemes, Algorithms, and Tools* [M]. Springer Berlin Heidelberg, 2008.
- [4] 周东华, 叶昊, 王桂增. 基于观测器方法的故障诊断技术若干重要问题的探讨[J]. *自动化学报*, 1998, 24(3): 338-344.
- [5] ZHOU D H, YE H, WANG G Z. Discussion of some important issues of observer based fault diagnosis technique [J]. *Acta Automatica Sinica*, 1998, 24(3): 338-344. (in Chinese)
- [6] 屠园园, 王大轶, 李文博. 基于降维观测器的最优故障诊断算法研究[J]. *中国空间科学技术*, 2017.
- [7] TU Y Y, WANG D Y, LI W B. Research on optimal fault diagnosis algorithm based on reduced-order observer[J]. *Chinese Space Science and Technology*, 2017. (in Chinese)
- [8] 文传博, 邓露, 吴兰. 基于滑模观测器和广义观测器的故障估计方法[J]. *自动化学报*, 2017: 1-8.
- [9] WEN CH B, DENG L, WU L. Fault Estimation Approaches Based on Sliding Mode Observer and Descriptor Observer[J]. *Acta Aeronautica et Astronautica Sinica*, 2017: 1-8. (in Chinese)

- [7] NGUANG S K, ZHANG P, DING S. Parity based fault estimation for nonlinear systems: an LMI approach[C]. *American Control Conference*. IEEE, 2006:6.
- [8] 王征,高炜欣,陈义,等. 控制系统中故障检测向量的解耦及次优设计[J]. *南京理工大学学报*, 2017(4):472-478.  
WANG ZH, GAO W X, CHEN Y, et al.. Decoupling and sub-optimal design of fault detection vector for control system[J]. *Journal of Nanjing University of Science and Technology*, 2017(4): 472-478 (in Chinese)
- [9] 孙蓉,刘胜,张玉芳. 基于参数估计的一类非线性系统故障诊断算法[J]. *控制与决策*, 2014,29(3): 506-510.  
SUN R, LIU SH, ZHANG Y F. Fault diagnosis algorithm of a class of nonlinear system based on parameter estimation [J]. *Control and Decision*, 2014,29(3):506-510. (in Chinese)
- [10] 王君,姚晓婉,李炜. NNCS 混合容错控制方法[J]. *控制与决策*, 2017,1-13.  
WANG J, YAO X W, LI W. Hybrid fault-tolerant control method research of NNCS [J]. *Control and Decision*, 2017:1-13. (in Chinese)
- [11] 李业波,李秋红,王健康. 基于 ImOS-ELM 的航空发动机传感器故障自适应诊断技术[J]. *航空学报*, 2013, 34(10):2316-2324.  
LI Y B, LI Q H, WANG J K. Sensor fault adaptive diagnosis of aero-engines based on ImOS-ELM [J]. *Acta Aeronautica et Astronautica Sinica*, 2013, 34(10):2316-2324 (in Chinese)
- [12] 鲁峰,黄金泉,吕怡秋. 基于非线性自适应滤波的发动机气路部件健康诊断方法[J]. *航空学报*, 2013, 34(11):2529-2538.  
LU F, HUANG J Q, LV Y Q. Design and simulation Validation of an integrated on-board Aircraft engine diagnostic architecture[J]. *Acta Aeronautica et Astronautica Sinica*, 2013, 34(11): 2529-2538. (in Chinese).
- [13] GAO Z, CECATI C, DING S X. A Survey of Fault Diagnosis and Fault-Tolerant Techniques—Part II: Fault Diagnosis With Knowledge-Based and Hybrid/Active Approaches [J]. *IEEE Transactions on Industrial Electronics*, 2015, 62(6):3768-3774.
- [14] PATTON R J, LOPEZ-TORIBIO C J, UPPAL F J. Artificial Intelligence approaches to fault diagnosis for dynamic systems[J]. *International Journal of Applied Mathematics & Computer Science*, 1999, 9(3):471-518.
- [15] 陈子琴,高向东,王琳. 大功率盘形激光焊缝背面宽度预测[J]. *光学精密工程*, 2017, 25(9): 2524-2531.  
CHEN Z Q, GAO X D, WANG L. Weld width prediction of weldment bottom surface in high-power disk laser welding [J]. *Opt. Precision Eng.*, 2017, 25(9): 2524-2531. (in Chinese)
- [16] 叶建华,高诚辉,江吉彬. 五轴机床旋转轴误差的在机测量与模糊径向神经网络建模[J]. *光学精密工程*, 2016, 24(4): 826-834.  
YE J H, GAO CH H, JIANG J B. On-machine measurement and fuzzy RBF neural network modeling for geometric errors of rotary axes of five-axis machine tools [J]. *Opt. Precision Eng.*, 2016, 24(4): 826-834. (in Chinese)
- [17] 张思忠,赵继,冀世军,等. 精密加工实验台热误差建模与补偿方法的对比分析[J]. *光学精密工程*, 2016, 24(10s): 520-526.  
ZHANG E ZH, ZHAO J, JI SH J, et al.. Comparative analysis on thermal error modeling and compensation method of precision matching test brch [J]. *Opt. Precision Eng.*, 2016, 24(10s): 520-526. (in Chinese)
- [18] 秦国华,谢文斌,王华敏. 基于神经网络与遗传算法的刀具磨损检测与控制[J]. *光学精密工程*, 2015, 23(5): 1314-1321.  
QIN G H, XIE W B, WANG H M. Detection and control for tool wear based on neural network and genetic algorithm [J]. *Opt. Precision Eng.*, 2015, 23(5): 1314-1321. (in Chinese)
- [19] 葛哲学,杨拥民,胡政. 一种新颖的直升机舵回路故障诊断方法[J]. *航空学报*, 2006, 27(6): 1122-1126.  
GE ZH X, YANG Y M, HU ZH. A new fault diagnosis method of helicopter actuator loop [J]. *Acta Aeronautica et Astronautica Sinica*, 2006, 27(6):1122-1126. (in Chinese)
- [20] 龚学兵,王日新,徐敏强. 基于数据关联性分析的飞轮异常检测[J]. *航空学报*, 2015, 36(3): 898-906.  
GONG X B, WANG R X, XU M Q. Abnormality detection for flywheels based on data association analysis[J]. *Acta Aeronautica et Astronautica Sinica*, 2015, 36(3):898-906. (in Chinese)
- [21] SOBHANI-TEHRANI E, TALEBI H A, KHALAST-

- CHI K. Hybrid fault diagnosis of nonlinear systems using neural parameter estimators [J]. *Neural Networks the Official Journal of the International Neural Network Society*, 2014, 50(2):12.
- [22] KHALASTCHI E, KALECH M, ROKACH L. A hybrid approach for improving unsupervised fault detection for robotic systems [J]. *Expert Systems with Applications*, 2017, 81:372-383.
- [23] BIALKE B. High fidelity mathematical modeling of reaction wheel performance [J]. *Advances in the Astronautical Sciences*, 1998, 98:483-496.
- [24] HORNIK K, STINCHCOMBE M, WHITE H. *Multilayer feedforward networks are universal approximators* [M]. Elsevier Science Ltd. , 1989.

作者简介:



赵琳(1968—),男,黑龙江哈尔滨人,教授,博士生导师,主要从事惯性导航技术、卫星导航技术、组合导航技术。E-mail: zhaolin@hrbeu.edu.cn



郝勇(1979—),男,吉林吉林市人,工学博士,助理研究员,主要从事飞行器控制与任务规划等方面研究,E-mail: haoyong@hrbeu.edu.cn



王艺鹏(1990—),男,河北石家庄人,博士研究生,2010年于哈尔滨工程大学获得学士学位,主要人工智能,系统故障诊断等方面研究。E-mail: wangyipeng@hrbeu.edu.cn