

基于 IL-UIO 与 SVMD 的轧机主传动系统多故障诊断*

张瑞成, 何 昊, 梁卫征
(华北理工大学电气工程学院 唐山, 063210)

摘要 针对轧机主传动系统多故障同时发生时观测器无法辨识的问题,提出一种基于模型残差与信号分解相结合的故障诊断方案。首先,考虑系统内部等效电流环和非线性摩擦阻尼,建立轧机主传动系统的多故障数学模型;其次,设计迭代学习未知输入观测器(iterative learning-unknown input observer, 简称 IL-UIO)用于系统故障检测,并引入 Lyapunov 理论和线性矩阵不等式来证明所提观测器的收敛性;然后,将观测器产生的耦合残差信号作为原始信号,使用连续变分模态分解(successive variational mode decomposition, 简称 SVMD)对其进行处理,计算分量的能量熵和模糊熵,并利用支持向量机对熵特征进行多故障辨识;最后,对 2 030 mm 冷轧机组进行了数值模拟。仿真结果表明,IL-UIO 方法能够快速跟踪系统,电机角速度估计误差小于 0.27%,利用 SVMD 熵特征可以准确识别故障类型。

关键词 故障诊断;轧机主传动系统;未知输入观测器;连续变分模态分解
中图分类号 TH113;TP273;TP29

0 引 言

在工业自动化和控制领域,轧机主传动系统是由数百个部件组成的复杂系统,为金属加工行业的关键组成部分。这些部件之间形成了复杂的关系,并且相互影响。由于轧制车间的工作环境恶劣以及机器长期运行,关键部件容易损坏或失效^[1]。目前,复合故障诊断的难点主要有:①复合故障通常在多个关键部件内部发生和演化,部件之间存在着时空相关性和相互作用;②复合故障与其对应的单个故障之间的关系是强相关的,而不仅仅是线性累积^[2]。

现有的复合诊断方法中,基于模型的方法通过物理规律和数学模型,为特定的诊断结果提供了解释性。同时,该方法能够进行性能评估,通过模拟不同故障场景,提前产生可能发生的故障数据,为数据驱动提供了可靠的故障数据来源。文献[3-4]考虑了多故障发生,但假设多部件不会同时失效。文献[5]提出了多个观测器用于检测故障,但每个观测器只对一个故障敏感。文献[6]的每个观测器对除一种故障之外的所有故障都敏感。文献[7]设计了一组观测器来分别隔离主传动的多重故障,但其多故障只影响单个状态变量,是多组单故障的线性累加。在针对复合故障诊断的研究中,当主传动系统

多故障同时发生时,由于多个系统状态变量耦合变化,基于模型的方法无法对其每个故障进行准确辨识,因此需要开发更加稳健与准确的诊断工具。

近年来,由于未知输入观测器能够解耦外部干扰和建模的不确定性,受到了广泛的关注和应用^[8]。当复合故障发生时,IL-UIO 可以检测到故障的发生,但无法对每个故障进行辨识。同时,其产生的残差信号中包含复合故障信息,为信号分解提供了可靠的数据来源,解决了数据驱动在复合诊断中的困难。在处理非平稳和非线性的残差数据集分解过程中,常用的方法有经验模态分解^[9](empirical mode decomposition, 简称 EMD)、局部均值分解^[10](local mean decomposition, 简称 LMD)等。文献[11]采用变分模态分解(variational mode decomposition, 简称 VMD),提出将信号分解为若干个本征模态分量的完全非递归方法。文献[12]提出了 SVMD,其不需要知道模式的数量,与 VMD 相比具有较低的计算复杂度,并且回避了初始中心频率确定的问题,从 SVMD 获得的多种模式中选择包含故障特征信息的有用模式,并进一步分析确定复合故障信息。

本研究针对轧机主传动系统的复合故障诊断问题,提出了 IL-UIO-SVM 的故障诊断方案,设计了

* 河北省自然科学基金资助项目(F2018209201);唐山市人才资助项目(B202302009);唐山市科技局科技计划资助项目(22130213G)

收稿日期:2024-06-27;修回日期:2024-08-22

IL-UIO 来检测主传动复合故障的发生。当检测到系统发生故障时,利用 SVM 对观测器产生的耦合残差信号进行分解,增强了故障特征,并利用支持向量机^[13](support vector machine, 简称 SVM)对复合故障中各个故障进行辨识。与现有方法相比,所提方法解决了多个故障同时发生时基于模型的方法无法隔离故障的问题,以及数据驱动方法中数据来源和可靠性问题,为复合故障诊断提供了一种新思路。

1 多故障系统建模

主传动系统是由电机、弹性连接轴、减速机、轧辊和各种联轴器组成的复杂系统,其中电机和轧辊是具有较大惯性的部件,而联接轴属于较轻的弹性部件。为了便于分析,一般利用集中质量法在不脱离实际的情况下,将主传动系统理想化为电机和轧辊组成的二质量弹簧系统^[14]。轧机主传动系统力学模型如图 1 所示。




图 1 轧机主传动系统力学模型

Fig.1 Mechanical model of main drive system of mill

轧机主传动系统由两个等式构成,分别是以轧辊参数为主和以直流电机为主的方程,即

$$J_m \ddot{\theta}_m + C_m \dot{\theta}_m + K(\theta_m - \theta_L) = T_m \quad (1)$$

$$J_L \ddot{\theta}_L + C_L \dot{\theta}_L + K(\theta_L - \theta_m) = T_L + T_f \quad (2)$$

其中: J_m 、 J_L 分别为电机和负载的转动惯量; T_m 、 T_L 分别为电机电磁转矩和负载阻力矩,且 $T_m = \phi I_c$; C_m 、 C_L 分别为电机和负载的阻尼系数; K 为弹性轴阻尼系数; T_f 为轧辊与轧件之间的摩擦转矩,且 $T_f = \mu P_a R$, P_a 为轧制力, R 为轧辊半径, μ 为辊间混合摩擦因素。

μ 为参数 a 、 b 、 c 和轧辊与轧件间的相对速度 v 的非线性函,即 $\mu = a - bv + cv^2$, 且 $v = R\dot{\theta}_L$ 。

针对主传动系统的数学建模,通常以电流和负载阻力矩的输入为主,然而根据轧制车间的实际调查结果,主传动系统的实际输入仅为电流。因此,为了更贴合实际系统,考虑将内部两个电流环等效为一个电流内环和一个带弱磁调速的单电枢电流环,形成双闭环控制系统,将负载力矩转化为电流。由于此时折合到每个电机电枢上的轧辊转动惯量为原来的一半,因此有

$$2\phi I - 2T_L = J\ddot{\theta}_m \quad (3)$$

其中: ϕ 为电机转矩系数; I 为电机额定电流; $J = J_m + J_L = GD^2/4g$, 为双电枢电机轴上的转动惯量, GD^2 为双电枢电机总飞轮矩; $T_L = GD^2\ddot{\theta}_m/8g + \phi I$ 。

定义主传动系统状态变量矩阵和输入矩阵分别为 $x = [\dot{\theta}_m \quad \dot{\theta}_L \quad \theta_m - \theta_L]^T$ 和 $u = I$, 其中 $\dot{\theta}_m$ 为电机角速度; $\dot{\theta}_L$ 为负载角速度。

考虑系统外部干扰和非线性因素的主传动故障模型为

$$\begin{cases} \dot{x} = Ax + Bu + \Gamma(x) + B_a f_i + Dd \\ y = Cx \end{cases} \quad (4)$$

其中: $D = [1 \quad 1 \quad 0]^T$, 为干扰分布矩阵; $d = 3.6 \text{ randsin}(10\pi t)$, 为系统受到的外部干扰^[14];

f_i 为故障函数; $B_a = \begin{bmatrix} 1 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 0 & 0 \end{bmatrix}^T$, 为故障分布矩阵;

$$B = [\phi/J_m \quad \phi/J_L \quad 0]^T;$$

$$A = \begin{bmatrix} -\frac{C_m}{J_m} & 0 & -\frac{k}{J_m} \\ 0 & -\frac{bP_a R^2 + C_L}{J_L} & \frac{k}{J_L} \\ 1 & -1 & 0 \end{bmatrix}; C = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix};$$

$$\Gamma(x) = \begin{bmatrix} 0 \\ \frac{cP_a R^3 x_2^2 - 1/2(J_m + J_L)x_2 + aP_a R}{J_L} \\ 0 \end{bmatrix}。$$

2 观测器设计

根据主传动系统数学模型,设计迭代学习未知输入观测器为

$$\begin{cases} \dot{Z} = FZ + Ly(t, k) + TBu(t, k) + \\ \quad T\Gamma(\hat{x}(t, k)) + TB_a \hat{f}_a(t, k) \\ \hat{x}(t, k) = Z + Ny(t, k) \\ \hat{y}(t, k) = C\hat{x}(t, k) \end{cases} \quad (5)$$

其中: $Z \in R^m$, 为观测器的中间状态; $\hat{x}(t, k) \in R^n$ 、 $\hat{y}(t, k) \in R^p$ 分别为 $x(t, k)$ 和 $y(t, k)$ 第 k 次迭代周期的观测值; F 、 L 、 T 、 N 为观测器增益矩阵。

由于矩阵 $[I \quad C]^T$ 列满秩, 所以非奇异矩阵 T 和 N ^[15] 满足

$$T + NC = I \quad (6)$$

假设 1 式(5)中的观测器增益满足以下条件

$$\begin{cases} L - FN = W \\ TA - WC = F \end{cases} \quad (7)$$

假设2 系统中的非线性项 $\mathbf{F}(x(t, k))$ 满足 Lipschitz 条件,即

$$\|\mathbf{F}(\hat{x}(t, k)) - \mathbf{F}(x(t, k))\| \leq \gamma \|\hat{x}(t, k) - x(t, k)\| \quad (8)$$

其中: γ 为 Lipschitz 常数。

定理1 对于满足假设1和假设2的系统式(4),存在正定矩阵 P 、 F 和常数 α 、 β 、 γ ,并且满足

$$\mathbf{\Pi} = \begin{bmatrix} \mathbf{\Pi}_1 & \mathbf{\Pi}_2 & -TD \\ - & \mathbf{\Pi}_3 & -K_2CTD \\ - & - & -\alpha^2 I \end{bmatrix} < 0 \quad (9)$$

其中: $\mathbf{\Pi}_1 = C^T C + P(F + \gamma T)$; $\mathbf{\Pi}_2 = TB_a + C(K_1 + K_2(F + \gamma T))$; $\mathbf{\Pi}_3 = K_2CTB_a - \beta^2 I$; K_1 、 K_2 为增益项。

当 $\mathbf{\Pi} < 0$ 时,观测器的状态误差渐近稳定,证明如下。

定义非线性估计误差为

$$\mathbf{e}_r(t, k) = \mathbf{F}(\hat{x}(t, k)) - \mathbf{F}(x(t, k)) \quad (10)$$

定义故障估计误差为

$$\mathbf{e}_f(t, k) = \hat{f}_a(t, k) - f_a(t) \quad (11)$$

定义故障迭代学习率为

$$f(t, k+1) = \delta [K_1 \mathbf{e}_y(t, k) + K_2 \dot{\mathbf{e}}_y(t, k)] + \hat{f}(t, k) \quad (12)$$

其中: δ 为迭代学习估计率。

对 $\mathbf{e}_x(t, k)$ 求一阶倒数,并代入式(6)和式(7),得到

$$\mathbf{e}_x(t, k) = T\dot{\mathbf{x}}(t, k) - \dot{\mathbf{Z}} = F\mathbf{e}_x(t, k) + T\mathbf{e}_r(t, k) + TB_a \mathbf{e}_f(t, k) - TDd(t) \quad (13)$$

选取 Lyapunov 函数,即

$$V_k = \mathbf{e}_x^T(t, k) P \mathbf{e}_x(t, k) + \mathbf{e}_f^T(t, k) Q^{-1} \mathbf{e}_f(t, k) > 0 \quad (14)$$

将 V_k 拆分为 $V_k = V_{k1} + V_{k2}$,并对 V_{k1} 沿时间方向求一阶导数,得到

$$\begin{aligned} \dot{V}_{k1} &= \dot{\mathbf{e}}_x^T(t, k) P \mathbf{e}_x(t, k) + \mathbf{e}_x^T(t, k) P \dot{\mathbf{e}}_x(t, k) = \\ & 2\mathbf{e}_x^T(t, k) P F \mathbf{e}_x(t, k) + 2\mathbf{e}_x^T(t, k) P T \mathbf{e}_r(t, k) + \\ & 2\mathbf{e}_x^T(t, k) T B_a \mathbf{e}_f(t, k) - 2\mathbf{e}_x^T(t, k) T D d(t) \end{aligned} \quad (15)$$

考虑迭代学习对于系统稳定性的影响,函数 V_{k2} 随迭代轴的增量为

$$\begin{aligned} \Delta V_{k2} &= 2\mathbf{e}_f^T(t, k) ((K_1 C + K_2 C F) \mathbf{e}_x(t, k) + \\ & K_2 C T B_a \mathbf{e}_f(t, k) + K_2 C T \mathbf{e}_r(t, k) - \\ & K_2 C T D d(t)) \end{aligned} \quad (16)$$

分别考虑噪声和估计误差对残差的影响,设计优化函数提供系统的鲁棒性,即

$$\begin{cases} J_1 = \int_0^t (\mathbf{e}_y^T(t, k) \mathbf{e}_y(t, k) - \alpha^2 d^T(t) d(t)) dt \\ J_2 = \int_0^t (\mathbf{e}_y^T(t, k) \mathbf{e}_y(t, k) - \beta^2 \mathbf{e}_f^T(t, k) \mathbf{e}_f(t, k)) dt \end{cases} \quad (17)$$

根据假设2,随迭代学习过程渐近收敛,即

$$\begin{aligned} \dot{V}_k &= 2\mathbf{e}_y^T(t, k) \mathbf{e}_y(t, k) - \beta^2 \mathbf{e}_f^T(t, k) \mathbf{e}_f(t, k) - \\ & \alpha^2 d^T(t) d(t) + \dot{V}_{k1} + \Delta V_{k2} \leq 2\mathbf{e}_f^T(t, k) (K_1 C + \\ & K_2 C F + \gamma K_2 C T) \mathbf{e}_x(t, k) - 2\mathbf{e}_x^T(t, k) T D d(t) + \\ & 2\mathbf{e}_x^T(t, k) T B_a \mathbf{e}_f(t, k) + 2\mathbf{e}_f^T(t, k) K_2 C T B_a \times \\ & \mathbf{e}_f(t, k) - \alpha^2 d^T(t) d(t) - 2\mathbf{e}_f^T(t, k) \times \\ & K_2 C T D d(t) - \beta^2 \mathbf{e}_f^T(t, k) \mathbf{e}_f(t, k) + \\ & 2\mathbf{e}_x^T(t, k) (C^T C + P F + \gamma P T) \mathbf{e}_x(t, k) = \mathbf{\Omega}^T \mathbf{\Pi} \mathbf{\Omega} \end{aligned} \quad (18)$$

其中: $\mathbf{\Omega} = [\mathbf{e}_x \quad \mathbf{e}_f \quad d]^T$ 。

因此,当 $\mathbf{\Pi} < 0$ 时系统状态渐近稳定,证毕。

3 复合故障辨识

3.1 SVMD 信号分解

SVMD 应用 VME 对信号进行依次分解,并添加一些约束条件以避免收敛到先前提取的模态分量,直到提取的所有模态分量小于阈值。

假设输入信号 $f(t)$ 被分解为两个信号^[16],即

$$f(t) = u_L(t) + f_r(t) \quad (19)$$

其中: $u_L(t)$ 为第 L 个模态分量; $f_r(t)$ 为获得的模数和信号未处理部分的总和。

$$f_r(t) = \sum_{i=L-1} u_i(t) + f_u(t) \quad (20)$$

SVMD 通过迭代可以找到第1个模态分量,其迭代方程为

$$\hat{u}_L^{n+1}(\omega) = \frac{\Delta_1}{(1 + \alpha^2(\omega - \omega_L^n)^4) \Delta_2'} \quad (21)$$

其中: $\Delta_1 = \hat{f}(\omega) + \alpha^2(\omega - \omega_L^n)^4 \hat{u}_L^n(\omega) + \hat{\lambda}(\omega)/2$; $\Delta_2 = 1 + 2\alpha(\omega - \omega_L^n)^2 + \sum_{i=1}^{L-1} 1/\alpha^2(\omega - \omega_i)^4$; α 为数据保真度约束的平衡参数,可以通过拉格朗日乘数法求解。

将 ω 的更新方程近似表示为

$$\omega_L^{n+1} = \int_0^\infty \omega \left| \hat{u}_L^{n+1}(\omega) \right|^2 d\omega / \int_0^\infty \left| \hat{u}_L^{n+1}(\omega) \right|^2 d\omega \quad (22)$$

给出拉格朗日乘数 λ ,采用双升法得到该方法的修正方程为

$$\hat{\lambda}^{n+1} = \hat{\lambda}^n + \tau \dot{\lambda} \quad (23)$$

其中: τ 为更新参数; $\dot{\lambda} = \hat{f}(\omega) - \left(\hat{u}_L^{n+1}(\omega) + f_u^{n+1}(t) + \sum_{i=1}^{L-1} u_i^{n+1}(\omega) \right)$ 。

通过逐步迭代和调整,能够有效地从复杂信号中分离出单独的模态,每个模态具有特定的频率特征,可用于信号分析。具体步骤如下:

- 1) 输入观测器产生的残差信号,检查信号长度,确保输入信号的长度为偶数;
- 2) 对残差信号和噪声进行预处理,使用滤波器估算信号中的噪声部分,同时计算信号的傅里叶变换以及对应的频率向量;
- 3) 根据参数 Ω 选择初始化频率中心,通过迭代过程更新每个模态的频谱和对应的中心频率,同时调整对偶变量以优化目标函数;
- 4) 逐渐增加平衡参数 α ,分离出更纯净的模态,在每次 α 增加后,重置相关参数和变量;
- 5) 对提取的每个模态进行逆傅里叶变换,并从扩展后的信号中去除镜像部分,得到最终的模态分解结果。SVMD 算法流程如图 2 所示。




图 2 SVMD 算法流程

Fig.2 Flow chart of SVMD algorithm

3.2 SVMD 熵特征

由于 SVMD 所分解出的 IMF 分量包含从高频到低频分布的频带,为了定量展现出主传动系统振动信号能量分布与故障状态的变化关系,提出了基于 SVMD 能量熵和模糊熵的方法来表现能量的大小^[17],具体原理如下。

- 1) SVMD 能量熵定义为

$$H_x = - \sum_{i=1}^n p_i \log p_i \quad (24)$$

其中: p_i 为第 i 个 IMF 占整个分量的比重。

- 2) SVMD 模糊熵定义为

$$F_x = \sum_{j=1}^n \omega_j \left(\sin \frac{\pi S_k \langle x_j, v_k \rangle}{2} + \sin \frac{\pi (1 - S_k \langle x_j, v_k \rangle)}{2} - 1 \right) \quad (25)$$

其中: n 为特征向量个数; ω_j 为当前特征值的权重; $S_k \langle x_j, v_k \rangle$ 为第 k 项特征值样本 x_j 与标准向量 v_k 的相似度。

- 3) 融合特征矩阵定义为

$$T_x = [H_x, F_x] \quad (26)$$

其中: H_x 、 F_x 分别为能量熵和模糊熵。

3.3 SVM 分类

SVM 的基本思路是将有限维度向量空间中线性不可分的样本映射到更高维度的向量空间里,再以间隔最大化的方式学习得到支持向量机^[18]。

当面对非线性可分数据时,使用核函数将数据映射到高维特征空间,得到最优函数为

$$f(x) = \text{sign} \left(\sum_{i=1}^M a_i y_i K(x_i, x_{sv}) + b \right) \quad (27)$$

其中: $K(x_i, x_{sv})$ 为核函数。

径向基函数为

$$K(x, y) = \exp \left(- \frac{\|x - y\|^2}{2\sigma^2} \right) \quad (28)$$

综上所述,本研究提出的多故障诊断方案流程如图 3 所示。




图 3 多故障诊断方案流程

Fig.3 Multi-fault diagnosis flowchart

4 实验仿真

为验证所提出方案的有效性,对某钢厂 2 300 mm 冷轧带钢 5 号机架进行了仿真实验。实验分为两部分:

①验证故障检测的可行性和残差数据的收集;②检查SVMD信号分解的准确性。系统型号参数见表1。

表1 系统型号参数

Tab.1 System model parameter

参数/单位	数值	参数/单位	数值
$T_L/(\text{N}\cdot\text{m})$	14 500	P_L/kN	7 807
$J_m/(\text{kg}\cdot\text{m}^2)$	1 552	I/A	1 720
$J_L/(\text{kg}\cdot\text{m}^2)$	1 542	$\phi/((\text{N}\cdot\text{m})\cdot\text{A}^{-1})$	29.1
$K/(\text{N}\cdot\text{m})$	5.93×10^6	$\Psi/((\text{N}\cdot\text{m})\cdot\text{A}^{-1})$	28
$C_m/(\text{N}\cdot(\text{m}\cdot\text{s}^{-1})^{-1})$	2×10^5	a	0.49
$C_L/(\text{N}\cdot(\text{m}\cdot\text{s}^{-1})^{-1})$	2×10^6	b	0.09
R/m	0.4	c	0.003 3

通过LMI工具箱计算定理,可以得到IL-UIO的增益矩阵为

$$F = \begin{bmatrix} -1.587\ 3 & -0.586\ 2 & -39.464\ 5 \\ -0.542\ 2 & -0.725\ 5 & 163.105\ 5 \\ 0.310\ 5 & -0.125\ 5 & 1.814\ 6 \end{bmatrix} \quad (29)$$

$$L = \begin{bmatrix} -2.951\ 7 & 1.284\ 9 & -51.136\ 5 \\ -0.593\ 0 & -1.626\ 3 & 97.245\ 1 \\ 0.799\ 3 & -0.046\ 1 & -0.246\ 1 \end{bmatrix} \quad (30)$$

$$K_1 = [-2.170\ 3 \quad 5.290\ 7 \quad -217.813\ 0] \quad (31)$$

$$K_2 = [-1.731\ 0 \quad 2.471\ 5 \quad 0.743\ 1] \quad (32)$$

本研究利用设计的IL-UIO检测主传动中的故障,考虑了3种常见的故障形式,以及3种情况耦合产生的6种状态。

工况1:轧机主传动系统电机发生电枢故障,即直流电机电流升高并波动,同时导致电机角速度产生波动。其故障函数为

$$f_1 = \begin{cases} 0 & (t < 4\ \text{s}) \\ 86(\sin(2\pi t)\cos(3\pi t)) & (4\ \text{s} \leq t \leq 16\ \text{s}) \\ 0 & (16\ \text{s} < t < 24\ \text{s}) \end{cases} \quad (33)$$

工况2:考虑轧机咬钢时出现的冲击振动故障,负载转矩增加,并且导致负载角速度波动。其故障

函数为

$$f_2 = \begin{cases} 0 & (t < 8\ \text{s}) \\ 50 + 45\sin(87\pi t) & (8\ \text{s} \leq t \leq 20\ \text{s}) \\ 0 & (20\ \text{s} < t < 24\ \text{s}) \end{cases} \quad (34)$$

工况3:由于长期运行对减速器齿轮产生磨损,因此导致齿轮错合对电机产生额外的转矩,使得电机角速度突增。其故障函数为

$$f_3 = \begin{cases} 0 & (t < 12\ \text{s}) \\ 500(\sin(24\pi t)\cos(2\pi t)) & (12\ \text{s} \leq t \leq 24\ \text{s}) \end{cases} \quad (35)$$

主传动系统故障分类见表2。

表2 主传动系统故障分类

Tab.2 Main drive system fault classification

故障型号	发生时间/s	故障标签
正常	0~4	000
f_1	4~8	001
f_3	20~24	100
f_1 和 f_2	8~12	011
f_2 和 f_3	16~20	110
f_1 、 f_2 和 f_3	12~16	111

主传动系统的状态变量估计值如图4所示。由图可见,观测器在0.05 s后电机角速度达到波峰,此时观测器的状态估计曲线与系统状态实际曲线拟合度较高,其估计误差小于0.27%,说明通过干扰解耦,可增强观测器对外部扰动的鲁棒性。

为了验证SVMD方法分解故障信号的有效性,将观测器产生的残差信号作为数据来源。使用SVMD对信号进行分解,其中容忍度设置为 1×10^{-6} ,平衡参数 α 起始值为 $\alpha_{\min}=10$,最大值 $\alpha_{\max}=12\ 000$ 。SVMD分解的各IMF分量见图5。

通过对表2中各故障的发生时间与图5中各分量的波动时间进行比较得知,IMF₂、IMF₅和IMF₆分量中可能分别包含故障 f_1 、 f_2 和 f_3 信号。




图4 主传动系统的状态变量与估计值
(a) Motor angular velocity and estimated value (b) Roll angular speed and estimated value (c) Angular displacement difference and estimated value

图4 主传动系统的状态变量与估计值
Fig.4 State variables and estimates of main drive system




图5 SVMD分解的各IMF分量

Fig.5 The IMF components decomposed by SVMD

将SVMD的分解结果与文献[19]提出的VMD分解结果进行比较,VMD分解的各IMF分量如图6所示。由图可知:IMF₁、IMF₂中故障 f_2 的特征在12 s之后被高频特征淹没,无法提取有用的故障信息;IMF₅中在12 s之后受到故障 f_3 的影响,改变了故障 f_1 原有的频率特征,影响了低频分量的故障特征。




图6 VMD分解的各IMF分量

Fig.6 IMF components of VMD decomposition

将3组状态变量进行SVMD分解,得到18组不同频谱特征的IMF分量,并进行熵特征提取,得到融合特征矩阵 T_x 。不同故障状态的特征向量见表3。将 T_x 与其对应标签作为SVM输入,核函数参数和惩罚因子的取值范围为[0.1, 1, 10, 100],训练集和测试集的比例为7:3。

将测试集输入SVM中,3类故障分类混淆矩阵

表3 不同故障状态的特征向量

Tab.3 Eigenvectors of different fault states

序号	H_x	F_x
1	7.459 2	0.008 577 2
2	6.573 1	0.001 578 1
3	4.683 3	0.005 089 9
$\vdots$	$\vdots$	$\vdots$
180	6.782 3	0.005 412 3

如图7所示。当3类故障同时发生时,测试样本的准确率到达98.56%。结果表明,该方案可以有效解决主传动系统的复合诊断问题。




图7 3类故障分类混淆矩阵

Fig.7 3 types of fault classification confusion matrix

当 f_1 和 f_2 同时发生时,重新采用IL-UIO对主传动系统进行观测,利用SVMD和熵特征获得新的特征数据集,并输入SVM中进行训练和测试。双故障分类混淆矩阵如图8所示。结果表明,其分类准确率为98.36%,验证了该模型的泛化能力。




图8 双故障分类混淆矩阵

Fig.8 Confusion matrix of double fault classification

5 结 论

1) 融合了基于模型和数据驱动的故障诊断方

法,提出了基于IL-UIO与SVMD结合的诊断方案,解决了多故障同时发生时观测器无法辨识的问题。

2) 设计了IL-UIO用于系统故障检测,分析了系统的收敛性和观测器增益的确定过程,并为信号分解提供可靠的数据来源。

3) 所提方案在2种或3种故障同时发生时都能保持高分类准确率,验证了方案的普适性和有效性,可广泛适用于实际工业环境中的多故障诊断需求。

参 考 文 献

- [1] QIAN C, HUA C C, ZHANG L L, et al. Adaptive neural torsional vibration suppression of the rolling mill main drive system subject to state and input constraints with sensor errors[J]. *Journal of the Franklin Institute*, 2020, 357(17): 12886-12903.
- [2] HUANG R Y, XIA J Y, ZHANG B, et al. Compound fault diagnosis for rotating machinery: state-of-the-art, challenges, and opportunities[J]. *Journal of Dynamics, Monitoring and Diagnostics*, 2023, 2(1): 13-29.
- [3] 杨新哲, 姜斌, 陈复扬, 等. 基于多观测器的一类过驱动系统主动容错控制设计[J]. *南京航空航天大学学报*, 2011, 43(增刊1): 1-4.
YANG Xinze, JIANG Bin, CHEN Fuyang, et al. Active fault tolerant control for over actuated system based on multiple observers[J]. *Journal of Nanjing University of Aeronautics & Astronautics*, 2011, 43(S1): 1-4. (in Chinese)
- [4] WANG R X, CHENG Y, XU M Q. Analytical redundancy based fault diagnosis scheme for satellite attitude control systems[J]. *Journal of the Franklin Institute*, 2015, 352(5): 1906-1931.
- [5] RÍOS H, EDWARDS C, DAVILA J, et al. Fault detection and isolation for nonlinear systems via HOSM multiple-observer [J]. *International Journal of Robust and Nonlinear Control*, 2012, 45(20): 534-539.
- [6] DEBELE Y, SHI H Y, WONDOSSE A, et al. Deep learning-based robust actuator fault detection and isolation scheme for highly redundant multirotor uavs [J]. *Drones*, 2023, 7(7): 437.
- [7] ZHANG R C, LI Z W, LIANG W Z. Fault detection and identification for rolling mill main drive system based on integrated observer under iterative learning strategy[J]. *Proceedings of the Institution of Mechanical Engineers*, 2023, 17(31): 31-47.
- [8] GAO C Y, ZHAO Q, DUAN G R. Robust actuator fault diagnosis scheme for satellite attitude control systems[J]. *Journal of the Franklin Institute*, 2013, 350(9): 2560-2580.
- [9] QION Y, RON Q, ZHAO L, et al. Detrend of vibration signals based on EMD-SSSC decomposition [J]. *Noise and Vibration Control*, 2024, 44(1): 187.
- [10] CHENG J S, ZHENG J D, YANG Y. A new non-stationary signal analysis method local feature scale decomposition method[J]. *Journal of Vibration Engineering*, 2012, 25(2): 215-220.
- [11] DRAGOMIRETSKIY K, ZOZZO D. Variational mode decomposition[J]. *IEEE Transactions on Signal Processing*, 2014, 62(3): 531-544.
- [12] NAZARI M, SAKHAEI S M. Successive variational mode decomposition[J]. *Signal Processing*, 2020, 174: 107610.
- [13] HUANG H S, FAN Q S, WEI J A, et al. An intelligent fault identification method of rolling bearings based on SVM optimized by improved GWO[J]. *Systems Science & Control Engineering*, 2019, 7(1): 289-303.
- [14] 张瑞成, 李志文, 梁卫征. 板带轧机主动系统的鲁棒故障检测与重构[J]. *振动、测试与诊断*, 2023, 43(1): 96-102.
ZHANG Ruicheng, LI Zhiwen, LIANG Weizheng. Robust fault detection and reconstruction of main drive system of strip mill[J]. *Journal of Vibration, Measurement & Diagnosis*, 2023, 43(1): 96-102. (in Chinese)
- [15] LIANG T, WANG M, HUANG C. Finite-time sensor fault diagnosis observer design for attitude control systems of satellite based on sampled-data descriptor systems [J]. *Transactions of the Institute of Measurement and Control*, 2019, 41(12): 3490-3506.
- [16] WANG X, MA J. Weak fault feature extraction of rolling bearing based on SVMD and improved MOMEDA [J]. *Mathematical Problems in Engineering*, 2021(1): 99-108.
- [17] LIU W, DINCER H, ETI S, et al. Gaussian-based hybrid approach to entropy for analyzing energy efficiency of emerging economies [J]. *Energy Reports*, 2021, 7: 2501-2511.
- [18] ZHANG Y, JIANG Y, CHEN Y, et al. Fault diagnosis of high voltage circuit breaker based on multi-classification relevance vector machine [J]. *Journal of Electrical Engineering & Technology*, 2020, 15(1): 413-420.
- [19] JIANG X, WANG J, SHEN C, et al. An adaptive and efficient variational mode decomposition and its application for bearing fault diagnosis [J]. *Structural Health Monitoring*, 2021, 20(5): 2708-2725.



第一作者简介:张瑞成,男,1975年3月生,博士、教授。主要研究方向为轧机电振动控制、轧钢自动化和机电耦合系统动态特性分析与控制等。曾发表《板带轧机主动系统的鲁棒故障检测与重构》(《振动、测试与诊断》2023年第43卷第1期)等论文。

E-mail: rchzhang@126.com