

# 基于三层信息融合的提升机制动系统故障诊断\*

李娟莉<sup>1,2,3</sup>, 王健<sup>4</sup>, 杨兆建<sup>1,2</sup>

(1. 太原理工大学机械工程学院 太原, 030024) (2. 煤矿综采装备山西省重点实验室 太原, 030024)

(3. 山西焦煤集团有限责任公司博士后科研工作站 太原, 030024)

(4. 山西潞安矿业有限责任公司古城煤矿 长治, 046000)

**摘要** 为了充分利用矿井提升机运行过程中的监测历史数据, 判定故障原因并进行准确定位, 将信息融合技术引入提升机的故障诊断中, 提出了一种基于三层多源信息融合故障诊断方法。该方法依据主成分分析法 (principal component analysis, 简称 PCA) 建立主元模型, 对原始完备数据集进行降维去噪, 实现特征提取, 完成数据层的融合; 特征层采用具有记忆功能的 Elman 神经网络作为融合算法, 不断调整权值对数据层各信息源提取出来的特征进行训练, 通过压缩融合信息量完成时间上的融合; 决策层使用 DS (dempster-shafer, 简称 DS) 证据理论对特征层训练输出的信息进行融合, 判定故障原因, 实现了空间上的融合; 最后依据 PCA 故障诊断原理, 定位故障发生的部位, 完成诊断过程。该融合方法通过对监测系统所测信息的合理选择、综合与利用, 对其进行空间和时间上的融合互补。试验结果表明, 该方法能够充分利用大量历史数据对系统进行诊断, 可以显著提高系统的可靠性。

**关键词** 信息融合; 提升机; 故障诊断; 制动系统

**中图分类号** TH113.1; TD534

## 引言

随着智能传感和监测技术的发展及物联网技术的集成与应用, 矿井提升机监测系统通过多传感器实时全方位的在线监测, 保存了海量提升机运行状态的相关信息, 多源信息融合技术<sup>[1-2]</sup>可对这些信息进行优化组合与提取, 生成诊断规则, 为提升机故障预警与诊断提供可靠依据。

目前信息融合技术在机械故障诊断领域已有一些初步的应用, 普遍采用单层 (数据层) 或两层 (特征层和决策层) 融合的诊断方法。Baraka 等<sup>[3-4]</sup>提出了基于人工神经网络的自适应故障检测和诊断方法, 并将该方法应用于旋转机械的故障诊断中, 可检测和隔离化学过程的干扰。Safizadeh 等<sup>[5]</sup>对滚动轴承时域和频域信号进行了融合与分类, 最终得出轴承条件和传感器性能之间的关系。汤宝平等<sup>[6]</sup>为了解决机械故障诊断应用中大量振动信号不能实时传输的问题, 研究了无线传感器网络多级分层信息融合的机械故障诊断方法。曹建福等<sup>[7]</sup>针对大型装备故障诊断中存在的高冲突证据问题, 对证据理论

算法进行了改进, 建立各条证据间的融合关系, 提高故障诊断的识别率。在矿井提升机故障诊断中, 信息融合技术的应用较少, 文献<sup>[8]</sup>针对提升机主轴系统故障耦合、特征微弱等问题, 以各数据样本为节点构建加权无向复杂网络模型, 该方法能准确对故障类型进行分类, 具有很高的故障识别精度。文献<sup>[9]</sup>充分利用了提升机制动器各传感器在时间和空间上的互补和冗余信息, 提高了提升机制动器诊断的可靠性。上述研究中, 基于数据层的信息融合方法能充分利用监测历史数据, 判定故障是否发生并对故障进行定位, 但无法判定故障的类型; 基于空间 (特征层) 和时间 (决策层) 上融合的两层信息融合的故障诊断方法能有效识别故障类型, 但有无法充分利用数据库中数据的缺陷。为了提高整个监测诊断系统的准确性和可靠性, 并充分利用历史数据, 笔者以提升机制动系统为研究对象, 提出了一种数据层、特征层、决策层三层多源信息融合的故障诊断方法, 将主成分分析法、人工神经网络和 DS 证据理论有机结合, 并通过试验验证了此融合结构在制动系统故障诊断应用中的有效性及正确性。

\* 山西省青年科技研究基金资助项目 (201601D021084)  
收稿日期: 2016-09-20; 修回日期: 2016-11-20

## 1 三层信息融合故障诊断系统结构

三层多源信息融合的故障诊断系统体系结构如图1所示。




图1 三层多源信息融合故障诊断系统体系结构

Fig.1 Fault diagnosis system structure of three layers of multi source information fusion

数据层主要融合由传感器直接采集的大量原始数据,利用PCA将这些多源信息转化到共同的参考描述空间,计算主元的得分向量并建立主元矩阵,之后确定主成分个数,进行特征提取。其优点是能够最大限度地利用原始数据进行综合与分析。

特征层以具有记忆功能的Elman神经网络作为融合算法,以数据层融合后各信息源提取出来的特征量作为输入,通过不断调整权值进行训练,输出符合性能指标的新特征量。该过程把各个特征信息进行了空间上的融合,得到的融合结果能够给决策层提供有用且完备的故障判决特征信息。其优点是稳定性强且提取并压缩整合了信息量。

决策层将不同时刻Elman神经网络的输出特征量作为证据,使用DS证据理论对其进行融合,选择最优决策准则判定故障原因,最后依据PCA的故障诊断原理对故障部位进行定位,得出诊断结果。

## 2 基于PCA的数据层融合

PCA是利用数据的二阶统计特性对原变量进行降维去噪的无监督的信号处理方法<sup>[10-11]</sup>。其基本思路是通过统计的方法将原高维变量简化为一组低维的线性无关的新变量,新变量保留了原有系统中大量有用的信息<sup>[12]</sup>。

### 2.1 主成分分析过程

1) 构造原始数据矩阵 $\mathbf{X}_{n \times m}$ 。根据式(1)对其进行标准化处理,处理后的矩阵记作

$$\hat{\mathbf{X}} = [\mathbf{X} - \mathbf{IB}] \mathbf{D}_\sigma^{-1/2} \quad (1)$$

其中: $n$ 为数据采样点个数; $m$ 为监测量个数; $\mathbf{I}$ 为 $n$ 维单位列向量; $\mathbf{B} = [b_1, b_2, \dots, b_m]$ 为均值向量; $\mathbf{D}_\sigma = \text{diag}[\sigma_1^2, \sigma_2^2, \dots, \sigma_m^2]$ 为方差矩阵; $b_i$ 和 $\sigma_i^2$ 分别为各变量的均值和方差。

2) 按式(2)计算矩阵 $\hat{\mathbf{X}}$ 的协方差矩阵 $\mathbf{C}$

$$\mathbf{C} = \frac{\hat{\mathbf{X}}^T \hat{\mathbf{X}}}{n-1} = \begin{bmatrix} c_{11} & c_{12} & \dots & c_{1m} \\ c_{21} & c_{22} & \dots & c_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ c_{m1} & c_{m2} & \dots & c_{mm} \end{bmatrix} \quad (2)$$

矩阵 $\mathbf{C}$ 中对角线的元素值的大小与变量的重要程度成正比,值越大则表明该变量越重要。

3) 对 $\mathbf{C}$ 进行特征分解,求出其特征值 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m$ 和其对应的特征向量矩阵 $\mathbf{P} = [p_1 \ p_2 \ \dots \ p_m]$ 。

4) 依式(3)计算主元矩阵 $\mathbf{W} = [\omega_1 \ \omega_2 \ \dots \ \omega_m]$ ,也叫做得分向量矩阵,其中 $\omega_i = \hat{\mathbf{X}} p_i$  ( $i=1, 2, \dots, m$ )表示矩阵 $\hat{\mathbf{X}}$ 在这个得分向量相对应的特征向量方向 $p_i$ 上的投影

$$\hat{\mathbf{X}} = \sum_{i=1}^m \omega_i p_i^T = \sum_{i=1}^k \omega_i p_i^T + \sum_{i=k+1}^m \omega_i p_i^T \quad (3)$$

5) 确定主成分个数。选取累积贡献率法<sup>[11]</sup>确定主成分个数。其定义为

$$\sum_{i=1}^k \lambda_i / \sum_{j=1}^m \lambda_j \geq 85\% \quad (4)$$

其中: $k$ 为主成分个数; $\lambda_i$ 为各得分向量对应的特征值。

前 $k$ 个得分向量包含了绝大部分有用的信息,这样用来进行诊断的样本数据就由 $m$ 维缩减到了 $k$ 维。

为了充分利用提升机运行过程中所监测的历史数据,以矿井提升机试验台JTP-1.2型提升机为研究对象,现选用试验过程中通过传感器所监测的提升机制动系统的39个运行过程关键监测变量(表1)来构建主元模型,监测并保存提升机运行一次过程中所采集的各个变量值,采样点数为500。

表1 监测变量表

Tab.1 Monitor variable schedule

变量编号	变量名称
1~8	1~8号闸的闸瓦位移
9~16	1~8号闸的弹簧力
17~24	1~8号闸的闸瓦温度
25~32	1~8号闸的闸瓦摩擦系数
33,34	左、右偏摆量
35,36	液压站油压、油温
37	总制动力矩
38	提升速度
39	加速度

首先建立正常主元模型。构造各变量原始数据矩阵,依式(1)对其进行标准化处理。预处理之后使用 Matlab 对其进行主成分分析,完成式(2)和(3)的计算,并利用累积方差贡献率法求取主元个数。故障主元模型的建立方法与此相同。

### 2.2 PCA 故障诊断基本原理

利用 PCA 的方法可以充分利用历史数据定性地检测和定位出故障,具体做法是将监测数据放入建好的正常主成分模型所构成的空间进行投影,如果其在主成分子空间上的投影大于在残差子空间上的投影则表示无故障,反之亦然。一般采用 Hotelling 提出的  $T^2$  统计量和  $Q$  统计量来判别监测数据在上述这两个子空间上投影的大小<sup>[10]</sup>。利用  $T^2$  统计量度量的原理是在主成分子空间求出  $T^2$  统计量及其阈值,如果被测数据在该子空间的  $T^2$  统计量超过阈值就判定有故障; $Q$  统计量度量的原理是用假设检验的方法求出其阈值,如被测数据在正常情况下的残差子空间的  $Q$  统计量大于阈值,则判定为有故障。 $T^2$  统计量定义如下

$$T_i^2 = x_i P_k \lambda^{-1} P_k^T x_i^T = w_i \lambda^{-1} w_i^T \quad (5)$$

其中:  $x_i$  为各变量在第  $i$  个采样点的值;  $P_k, \lambda^{-1}$  分别为正常主成分模型的特征向量和其对应的特征值。

$T^2$  统计量阈值的计算公式如下

$$T_\alpha^2 = \frac{k(m-1)}{m-k} F_{k,m-k,\alpha} \quad (6)$$

其中:  $k$  为主成分个数;  $m$  为变量个数;  $F_{k,m-k,\alpha}$  为置信水平为  $\alpha = 0.05$  且自由度为  $k$  和  $m-k$  的  $F$  分布的临界值。

无故障时,  $T^2$  统计量小于阈值  $T_\alpha^2$ 。

$Q$  统计量及其阈值的计算公式为

$$Q_i = x_i (I - P_k P_k^T) x_i^T \quad (7)$$

$$Q_\alpha = \theta_1 \left( \frac{c_\alpha h_0 \sqrt{2\theta_2}}{\theta_1} + \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1^2} + 1 \right)^{\frac{1}{h_0}} \quad (8)$$

其中:  $\theta_1 = \sum_{i=k+1}^m \lambda_i$ ;  $\theta_2 = \sum_{i=k+1}^m \lambda_i^2$ ;  $\theta_3 = \sum_{i=k+1}^m \lambda_i^3$ ;  $h_0 = 1 - \frac{2\theta_1 \theta_3}{3\theta_2^2}$ ;  $k$  为主成分个数;  $c_\alpha$  为置信水平为  $\alpha = 0.05$  的标准正态分布的下限值;  $m$  为变量个数。

依据各变量对各个主元的贡献图和其  $Q$  统计量的贡献图可以诊断故障的发生部位,具体实现方法在第 5 节试验中进行详细分析。由上面分析可以看出,PCA 故障诊断的方法能定位出故障,但无法确定是何种故障,为此,利用 PCA 进行数据层融合

后还需要进一步综合与分析处理。

### 3 基于 Elman 神经网络特征层融合

Elman 神经网络是一种典型的局部回归网络,相比反向传播神经网络(back propagation,简称 BP)、径向基神经网络(radial basis function,简称 RBF)等其他网络,其优势主要体现在:结构简单、具有记忆功能及训练时间短,具有适应时变特性及处理动态关系的能力,在小样本条件下同样适用,且稳定性强。其结构包括输入层、隐含层、承接层和输出层<sup>[13]</sup>,其中,输入层进行信号传输;承接层是 Elman 实现记忆功能的关键层,其原理是首先从隐含层接收反馈信号,并记忆该层神经元前一时刻的输出值,通过承接层的延迟与存储,再输入到隐含层,增加了网络的自学习能力;输出层起线性加权作用。Elman 神经网络结构如图 2 所示。




图 2 Elman 神经网络结构

Fig. 2 Structure of Elman neural network

其数学模型如式(9)

$$\begin{cases} x(k) = f(\omega^1 c(k) + \omega^2 u(k-1)) \\ c(k) = \alpha c(k-1) + x(k-1) \\ y(k) = g(\omega^3 x(k)) \end{cases} \quad (9)$$

其中:  $u()$ ,  $x()$ ,  $c()$ ,  $y()$  分别为输入层的输入、隐含层的输出、承接层的输出及输出层的输出;  $\omega^1, \omega^2, \omega^3$  分别为隐含层与承接层、输入层与隐含层、隐含层与输出层之间的连接权值;  $0 \leq \alpha < 1$  为自连接反馈增益因子;  $g(\cdot)$  为输出层神经元的传递函数,一般选用线性函数;  $f(\cdot)$  为隐含层神经元的非线性传递函数,通常选用 sigmoid 函数。

Elman 神经网络训练过程中,通过不断调整网络权值  $\omega^1, \omega^2, \omega^3$  的大小,使其达到规定的性能指标,从而满足实际应用需求。性能指标函数为

$$E = \sum_{k=1}^m [y(p) - t_k(p)]^2 \quad (10)$$

其中： $y(p)$ 为 $k$ 时刻输出层第 $p$ 个神经元的实际输出； $t_k(p)$ 为 $k$ 时刻第 $p$ 个神经元的期望输出； $m$ 为输出层输出神经元矢量的维数。

矿井提升机制动系统故障诊断的特征量经过上节数据层的融合作为 Elman 神经网络的输入向量。首先建立各故障的主元模型，建立方法见 2.1 节，然后按式(11)计算各得分向量的模

$$\omega_i = (\text{dot}(\omega_i, \omega_i))^{1/2} \quad (11)$$

收集 100 组神经网络的训练样本，在计算过程中发现有些故障主元模型的第 8 个得分向量的长度大小为零，所以取各故障的前 7 个主元作为特征量，如表 2 所示。

表 2 Elman 神经网络训练样本

Tab. 2 Elman neural network training sample

样本号	故障主元模型得分向量长度							故障模式
1	94.59	22.38	16.02	9.87	6.02	4.37	2.56	正常
2	90.59	29.38	21.03	17.87	11.42	8.27	4.56	敞不开闸
3	92.45	26.05	13.98	9.28	7.25	5.42	3.06	空动时间长
4	91.26	35.48	24.34	17.89	9.21	7.57	4.52	过卷
5	89.53	40.67	31.04	20.80	17.42	10.27	5.26	不能紧急制动
6	86.45	48.01	39.05	30.12	22.85	18.42	10.06	空动时间长
7	96.44	46.13	36.05	28.12	19.38	15.02	9.63	制动时间长
8	89.43	29.36	22.16	16.11	10.38	8.99	4.03	卡缸
9	95.92	43.31	35.98	27.68	19.78	14.76	10.36	制动时间长
10	85.54	48.01	38.65	38.98	21.89	17.72	12.36	空动时间长
⋮	⋮							⋮

利用 Matlab 神经网络工具箱中的相关函数对网络进行训练，输出结果作为决策层融合的输出。

## 4 基于 DS 的决策层融合

DS 证据理论是一种基于辨识框架的不确定性推理理论，具有处理不确定性信息的能力，可使诊断结果更为可靠<sup>[14]</sup>。在 DS 证据理论中，由互不相容的基本命题组成的完备集合作为辨识框架  $\Theta$ ，该框架的子集称为命题。分配给各命题的信任程度称为基本概率分配函数，定义如式(12)

$$\begin{cases} m(\varphi) = 0 \\ \sum_{A \subseteq 2^\Theta} m(A) = 1 \end{cases} \quad (12)$$

其中： $A$ 为命题；函数 $m$ 为 $A$ 的基本概率分配函数； $m(A)$ 反映对 $A$ 的信度大小。

信任度函数 $c$ 由式(13)定义，表示对命题 $A$ 的信任程度

$$c(A) = \sum_{B \subseteq A} m(B) \quad (\forall A \subseteq 2^\Theta) \quad (13)$$

似然函数 $p$ 定义如式(14)所示，表示对命题 $A$ 非假的信任程度。 $[c(A), p(A)]$ 表示 $A$ 的不确定区间

$$p(A) = \sum_{A \cap B \neq \varphi} m(B) \quad (14)$$

DS 证据理论的核心是 Dempster 合成规则，由于其可以综合不同专家或数据源的知识或数据，在信息融合等领域得到了广泛的应用。根据不同的证据体类型，在进行融合时需要采用不同的组合规则，由于在矿井提升机故障诊断过程中，数据具有耦合交叉特性，为了解决证据冲突问题，笔者采用了 Yager 组合规则生成新的基本概率分配函数，其定义如式(15)

$$m(A) = \begin{cases} \sum_{A_i \cap B_j = A} m_1(A_i) m_2(B_j) & (A \neq \Theta) \\ \sum_{A_i \cap B_j = A} m_1(A_i) m_2(B_j) + k & (A = \Theta) \end{cases} \quad (15)$$

其中： $k = \sum_{A_i \cap B_j = \varphi} m_1(A_i) m_2(B_j)$ 为证据的冲突程度。

DS 证据理论故障诊断决策的基本思路是：首先，将被测对象的典型故障原因作为辨识框架中的每个命题组成命题集合，构造故障辨识框架；其次，从信息中提取对故障敏感的特征向量作为证据体，并为每个证据体构造基本概率赋值函数；然后，依据证据体的类型选取合成规则，对证据体进行融合；最后，将结果进行比较分析，最终得出故障原因。

## 5 试验

### 5.1 试验条件预设

为了验证融合算法的有效性正确性，首先在试验台进行故障模拟。预先将 4 号闸的闸瓦间隙值调试设定为 3 mm，模拟 4 号闸的闸瓦间隙过大故障，依据煤矿安全规程，制动闸的闸瓦间隙值不得大于 2 mm，故将其设为诊断阈值。

### 5.2 试验过程

在上述试验条件下，求出各得分向量的模，利用 Elman 神经网络计算结果如表 3 所示。

利用上述融合结果构造辨识框架，将 7 个故障模式作为辨识框架的 7 个命题，用  $\Theta = \{\text{正常、敞不开闸、空动时间长、过卷、不能紧急制动、制动时间长、卡缸}\}$ 表示，为每个证据体构造基本概率赋值函数，其结果如表 4 所示。

表 3 Elman 融合结果  
Tab.3 Elman fusion results

故障编号	故障模式	Elman 融合结果							
1	正常	0.302 4	0.069 8	0.994 8	0.000 1	0.000 6	0.001 0	0.012 9	
2	敞不开闸	0.000 4	0.980 2	0.874 8	0.045 7	0.019 8	0.005 9	0.000 6	
3	空动时间长	0.000 6	0.218 9	0.992 3	0.012 3	0.008 7	0.010 4	0	
4	过卷	0.448 9	0.110 2	0.154 4	0.000 3	0.009 6	0.003 5	0.047 6	
5	不能紧急制动	0.000 6	0.030 8	0.005 2	0.015 9	0.083 3	0.006 2	0.006 1	
6	制动时间长	0.300 2	0.990 4	0.016 9	0.000 8	0.012 5	0.011 0	0.000 4	
7	卡缸	0.107 8	0.000 3	0.910 2	0.024 0	0.001 7	0	0.864 2	

表 4 证据体基本概率赋值

Tab.4 Basic probability assignment of evidence body

证据体	基本概率赋值结果							
$m_1$	0.212 6	0.050 9	0.730 1	0.000 1	0.000 4	0.000 9	0.001 1	
$m_2$	0.000 3	0.500 0	0.460 1	0.024 9	0.010 2	0.004 3	0.000 1	
$m_3$	0.000 5	0.176 5	0.798 8	0.009 0	0.006 7	0.008 7	0	
$m_4$	0.579 9	0.140 2	0.199 4	0.000 2	0.011 9	0.004 5	0.063 6	
$m_5$	0.000 4	0.034 8	0.006 3	0.017 9	0.930 4	0.007 2	0.006 5	
$m_6$	0.165 8	0.790 4	0.016 9	0.000 8	0.011 5	0.009 0	0.000 2	
$m_7$	0.062 8	0.000 3	0.490 2	0.014 0	0.000 8	0.000 3	0.464 2	

采用 Yager 组合规则对其进行融合,结果为:


$(m=0 \ 0 \ 0.168 \ 7 \ 0 \ 0.013 \ 6 \ 0 \ 0)$

### 5.3 试验结果

从该融合结果来看,可以判定命题 3 为决策结果,即为空动时间过长故障。对引起该故障的原因进行判别,判别过程如下:引起空动时间过长的直接原因是制动力矩不足,而弹簧故障、摩擦因数过大、闸瓦间隙过大及残压高等都有可能造成该结果,对上述原因进行一一验证。由于在试验前,对各闸的弹簧刚度和预压缩量都进行了检测,符合标准,故排除弹簧故障;且在提升机运行过程中经监测计算得出的摩擦因数及制动油残压处于正常范围,故该故障类型可判定为由于闸瓦间隙过大导致的制动力矩不足,从而进一步引发的空动时间过长故障。


明确了故障类型后,接下来就是对故障进行定位,查找故障源。在此依据 2.2 节所述的 PCA 故障诊断原理,对故障部位进行定位。分别计算正常主元模型和空行程过长故障主元模型中每个变量的 Q 统计量,并绘制各变量对 Q 统计量的贡献图(在此仅列出空行程时间过长故障下 Q 统计量贡献图和正常情况下不同的两个变量),如图 3 和图 4 所示。

由图 4 可以看出,发生故障时,在采样点 150 和 350 之间,第 4 和第 12 个变量的 Q 统计量贡献图和



(a) 第4个变量对Q统计量的贡献

(a) Contribution of the 4th variables to the Q statistics




(b) 第12个变量对Q统计量的贡献

(b) Contribution of the 12th variables to the Q statistics


图 3 正常情况下第 4 和第 12 变量对 Q 统计量贡献  
Fig.3 Contribution of the 4th and 12th variables to the Q statistics under normal conditions

正常情况相比整体向下发生了偏移,而其他变量的 Q 统计量贡献图和正常情况下相同。这是由于闸瓦间隙过大对应的闸瓦位移减小,在 Q 统计量贡献图上的表现为整体下移,第 4 和第 12 个变量分别为 4 号闸的闸瓦位移和弹簧力,由此可判定该故障发生的部位为 4 号闸。试验结果与预先物理模拟的故障完全吻合,从而验证了该融合算法的正确性。



(a) 第4个变量对Q统计量的贡献

(a) Contribution of the 4th variables to the Q statistics

(b) 第12个变量对 $Q$ 统计量的贡献(b) Contribution of the 12th variables to the  $Q$  statistics图4 空行程时间过长故障下第4和第12变量对 $Q$ 统计量贡献Fig.4 Contribution of the 4th and 12th variables to the  $Q$  statistics in long free-transmission time

## 6 结束语

为了充分利用监测系统中的历史数据,对矿井提升机制动系统故障进行可靠诊断,提出了基于三层多源信息融合的故障诊断方法,该方法通过对监测系统所测信息的合理选择、综合与利用,对其进行空间和时间上的融合互补。基于PCA的数据层融合使诊断结果更为完备;而基于Elman神经网络的特征层和基于DS证据理论的决策层上的时空融合则对故障进行了有效判别与诊断。三层的融合方法避免了单层和两层融合的固有缺陷。将三层多源信息融合技术成功应用到了提升机制动系统的故障诊断中,试验结果表明,该方法能够有效识别故障类型,可充分利用大量的历史数据对系统进行诊断,有效提高了诊断系统的性能。

### 参 考 文 献

- [1] Ai Li, Cheng Jiatang, Xiong Wei. Transformer fault diagnosis based on information fusion technology [J]. Sensors and Transducers, 2014, 167(3): 61-67.
- [2] Liu Xiaohua. Research of intelligent fault diagnosis model on multi-information fusion [J]. Journal of Computers, 2011, 6(6): 1254-1261.
- [3] Barakat M, Druaux F, Lefebvre D, et al. Self adaptive growing neural network classifier for faults detection and diagnosis [J]. Neurocomputing, 2011, 74 (18): 3865-3876.
- [4] Barakat M, Lefebvre D, Khalil M, et al. Parameter selection algorithm with self adaptive growing neural network classifier for diagnosis issues [J]. International Journal of Machine Learning and Cybernetics, 2013, 4 (3): 217-233.
- [5] Safizadeh M S, Latifi S K. Using multi-sensor data fusion for vibration fault diagnosis of rolling element

bearings by accelerometer and load cell [J]. Information Fusion, 2014, 18(1): 1-8.

- [6] 汤宝平, 邓兵, 邓蕾, 等. 无线传感器网络多级整合的机械故障诊断方法 [J]. 振动、测试与诊断, 2016, 36(1): 92-96.  
Tang Baoping, Deng Bing, Deng Lei, et al. Mechanical fault diagnosis method based on multi-level fusion in wireless sensor networks [J]. Journal of Vibration, Measurement & Diagnosis, 2016, 36 (1): 92-96. (in Chinese)
- [7] 曹建福, 曹雯. 基于改进证据理论的大型制造装备故障诊断 [J]. 振动、测试与诊断, 2012, 32(4): 532-538.  
Cao Jianfu, Cao Wen. Fault diagnosis of large manufacturing equipment based on improved evidence fusion theory [J]. Journal of Vibration, Measurement & Diagnosis, 2012, 32(4): 532-538. (in Chinese)
- [8] 董磊, 石瑞敏, 曾志强. 基于复杂聚类的提升机主轴系统故障诊断 [J]. 振动、测试与诊断, 2016, 36(4): 688-693.  
Dong Lei, Shi Ruimin, Zeng Zhiqiang. Fault diagnosis for spindle system of hoist based on complex network clustering [J]. Journal of Vibration, Measurement & Diagnosis, 2016, 36(4): 688-693. (in Chinese)
- [9] 王健. 基于信息融合技术的提升机制动系统与减速器故障诊断方法 [D]. 太原: 太原理工大学, 2012.
- [10] Gharavian M H, Almas G F, Ohadi A R, et al. Comparison of FDA-based and PCA-based features in fault diagnosis of automobile earboxes [J]. Neurocomputing, 2013, 121(9): 150-159.
- [11] Sharifi R, Langari R. Nonlinear sensor fault diagnosis using mixture of probabilistic PCA models [J]. Mechanical Systems and Signal Processing, 2017, 85 (2): 638-650.
- [12] Komari A H, Karim S, Komari A H. A new integrated on-line fuzzy clustering and segmentation methodology with adaptive PCA approach for process monitoring and fault detection and diagnosis [J]. Soft Computing, 2013, 17(3): 345-362.
- [13] Sun Yushan, Li Yueming, Zhang Guocheng, et al. Actuator fault diagnosis of autonomous underwater vehicle based on improved Elman neural network [J]. Journal of Central South University, 2016, 23(4): 808-816.
- [14] Hui K, Lim M, Leong M, et al. Dempster-shafer evidence theory for multi-bearing faults diagnosis [J]. Engineering Applications of Artificial Intelligence, 2017, 57(1): 160-170.



**第一作者简介:**李娟莉,女,1979年2月生,博士、副教授。主要研究方向为机电系统故障诊断。曾发表《提升机故障诊断不确定性推理方法》(《煤炭学报》2014年第39卷第3期)等论文。  
E-mail: lijuanli@tyut.edu.cn

