

引用格式:马波,苏方健,赵祎,等. 基于无限学生 t 混合模型聚类的机械故障预警方法[J]. 北京化工大学学报(自然科学版), 2020, 47(4): 74–80.

MA Bo, SU FangJian, ZHAO Yi, et al. A mechanical fault early warning method based on infinite student's t -mixture model clustering[J]. Journal of Beijing University of Chemical Technology (Natural Science), 2020, 47(4): 74–80.

基于无限学生 t 混合模型聚类的机械故障预警方法

马 波^{1,2} 苏方健¹ 赵 祎³ 蔡伟东¹

(1. 北京化工大学 机电工程学院, 北京 100029; 2. 北京化工大学 高端机械装备健康监控及自愈化北京市重点实验室, 北京 100029; 3. 中国商用飞机有限责任公司 上海飞机设计研究院, 上海 201210)

摘 要: 往复式压缩机、柴油机等复杂机械的振动信号往往呈现较强的非平稳特性, 导致传统单特征门限报警法的报警准确率较低。针对该问题, 提出一种基于无限学生 t 混合模型(infinite student's t -mixture model, iSMM) 聚类的机械故障预警方法: 首先, 通过提取机械振动信号特征构建高维特征空间, 并采用 iSMM 对其进行建模, 以描述机械设备的状态; 其次, 利用基于匹配的 KL 散度近似算法计算机械设备在历史正常状态和观测状态下的模型间距离; 最后, 将该距离与基于 3σ 准则自学习出的报警阈值进行比较, 实现故障预警。利用往复式压缩机故障案例对所提方法进行验证, 结果表明本文方法较单特征门限报警法报警准确率高且时效性好, 可有效地对复杂机械进行故障预警。

关键词: 故障预警; 机械设备; 无限学生 t 混合模型; 无监督学习

中图分类号: TH17 **DOI:** 10.13543/j.bhxbzr.2020.04.011

引 言

往复式压缩机、柴油机等复杂机械作为流程工业中的关键设备, 一旦出现故障而未及时发现, 将会给企业带来巨大的经济损失。目前, 企业主要采用单特征门限报警法(简称 SF 方法)对这些机械进行状态监测及故障预警, 以确保生产的安全稳定。然而复杂机械由于自身激励源多、传递路径复杂, 其振动信号呈现较强的非平稳特性, 致使 SF 方法常出现误报、漏报警现象^[1-2]。针对该问题, 一些学者对多特征融合的机械故障预警方法进行了研究。文献[3]基于双树复小波变换从机械振动信号中提取故障特征构建故障特征向量, 利用其训练出的反向传播神经网络模型实现对柴油机的故障预警。文献[4]利用最小二乘支持向量机对风力发电机的多种状态特征建模, 以实现故障预警。与 SF 方法相比, 上述两种方法不仅考虑了多项状态特征, 而且考虑了各特征间内在联系的变化, 从而大

幅提升了对复杂机械的故障预警效果, 但以上方法均需要大量故障样本训练预警模型, 而实际故障样本的稀缺限制了其应用^[5-6]。

文献[7]提出一种基于多元状态估计的机械故障预警方法, 其以概率密度采样的方式稀疏历史振动数据并构建过程记忆矩阵, 通过比较观测时段与历史正常时段下对应过程记忆矩阵的相似度, 实现对电厂辅助设备的故障预警。该预警方法基于设备历史运行工况相似性原理, 摆脱了对故障样本的依赖; 然而对于存在较多激励源的复杂机械, 该方法由于无法识别机械内部各激励源所激发激励信号的变化, 对机械局部故障不敏感, 导致预警时效性较差。

无限学生 t 混合模型(infinite student's t -mixture model, iSMM)是近年来提出的一种无监督学习聚类模型, 相比于传统聚类模型如高斯混合模型, 它不仅能以较好的鲁棒性来拟合数据的统计分布, 而且能够自学习数据的类数以避免出现过、欠拟合数据问题^[8-9]。凭借上述优点, iSMM 在图像分割、盲信号处理等领域已得到应用^[10-11]。iSMM 在拟合机械振动信号的统计分布时, 可根据历史振动数据自学习出机械内激励源的数量以及各激励信号服从的

收稿日期: 2019-12-23

第一作者: 男, 1977 年生, 副教授

E-mail: mabo@mail.buct.edu.cn

统计分布,从而为识别机械内各激励信号的变化提供有效方式。基于上述分析,本文提出一种基于 iSMM 聚类的机械故障预警方法,该方法利用 iSMM 拟合机械振动信号的统计分布,计算在观测时段和历史正常时段下对应的统计分布模型间距离,并将该距离与自适应确定的报警阈值作比较,实现故障预警。

1 iSMM 定义及其参数估计方法

1.1 无限学生 t 混合模型

iSMM 由无限个学生 t 分布加权线性组合构成,其概率密度函数如式(1)所示。

$$P(x_n) = \sum_{j=1}^{\infty} \pi_j t(x_n | \boldsymbol{\mu}_j, \boldsymbol{\Lambda}_j, \nu_j) \quad (1)$$

其中,

$$t(x_n | \boldsymbol{\mu}_j, \boldsymbol{\Lambda}_j, \nu_j) = \int_0^{\infty} N(x_n | \boldsymbol{\mu}_j, u_n \boldsymbol{\Lambda}_j) \Gamma\left(u_n \mid \frac{\nu_j}{2}, \frac{\nu_j}{2}\right) du_n \quad (2)$$

式中, π_j 为 iSMM 中第 j 个子成分的权重, $\pi_j \geq 0$ 且

$\sum_{j=1}^{\infty} \pi_j = 1$; $\boldsymbol{\mu}_j$ 为 iSMM 中第 j 个子成分的均值矩阵; $\boldsymbol{\Lambda}_j$ 为 iSMM 中第 j 个子成分的协方差矩阵; ν_j 为 iSMM 中第 j 个子成分的自由度; $N(\cdot)$ 为高斯分布概率密度函数, $\Gamma(\cdot)$ 为伽马分布概率密度函数^[10]; u_n 为一个服从 Gamma 分布的隐变量。

为使 iSMM 能够自学习数据的类数,模型参数需满足条件如式(3)~(5)所示。

$$\pi_j = \pi_j(\nu) = \nu_j \prod_{i=1}^{j-1} (1 - \nu_i) \quad (3)$$

$$\nu_j \sim B(1, \alpha) \quad (4)$$

$$Z_n \sim \text{Mult}(\boldsymbol{\pi}(\nu)) \quad (5)$$

式中, α 为正实数; Z_n 为隐变量,用于指示 x_n 所属的 iSMM 子成分,在利用 iSMM 拟合数据时,产生的互不重复的 Z_n 值的数量即数据的类数。

1.2 模型的参数估计

采用变分贝叶斯推断方法近似估计 iSMM 的参数,实现对数据统计分布的自学习。该参数估计方法求解快速,且求解精度可满足一般的工程需要。变分贝叶斯推断原理如下所述。

假设存在分布 p , 其内参数 $\Phi = \{\Phi_j\}_{j=1}^m$; p 的变分近似分布为 q , 则式(6)恒成立。

$$\ln(p(X)) = \int q(\Phi) \ln\left(\frac{p(X, \Phi)}{q(\Phi)}\right) d\Phi -$$

$$\int q(\Phi) \ln\left(\frac{p(\Phi|X)}{q(\Phi)}\right) d\Phi = F + \text{KL}(q \| p) \quad (6)$$

其中,

$$q(\Phi) = \prod_{i=1}^m q_i(\Phi_i) \quad (7)$$

式中, X 为观测样本, $X = \{x_n\}_{n=1}^N$; F 为 $\ln(p(X))$ 的变分下界; $\text{KL}(q \| p)$ 为 $q(\Phi)$ 和 $p(X, \Phi)$ 的 KL 散度。

由式(6)可知, F 越大, 则 $\text{KL}(q \| p)$ 越小, 即 $q(\Phi)$ 和 $p(X, \Phi)$ 越接近。令 F 最大化, 可得到迭代公式如式(8)所示。

$$\ln(q_j^*(\Phi_j)) = E_{i \neq j}[\ln(p(X, \Phi))] \quad (8)$$

其中,

$$E_{i \neq j}[\ln(p(X, \Phi))] = \int \cdots \phi_{i \neq j} \cdots \int \prod_{i \neq j}^m q_i(\Phi_i) \cdot$$

$$\ln(p(X, \Phi)) \prod_{i \neq j}^m d\Phi_i \quad (9)$$

式中, $q_j^*(\Phi_j)$ 表示对 $q_j(\Phi_j)$ 更新。

利用变分贝叶斯推断方法推断 iSMM 参数时, 式(7)可写成

$$q(\Phi) = q(Z)q(u)q(\boldsymbol{\mu}, \boldsymbol{\Lambda})q(\alpha) \quad (10)$$

另外, 由于 iSMM 部分参数集元素数量为无限而导致变分贝叶斯推断的计算无法收敛, 因此须设定截断参数 T , T 满足条件: 当 $j > T$, $\pi_j(\nu) = 0$ 且

$\sum_{j=1}^T \pi_j(\nu) = 1$ 。iSMM 的参数估计算法流程如下。

1) 选定观测样本 X 、 $\{\boldsymbol{\mu}_j, \boldsymbol{\Lambda}_j, \nu_j, \alpha\}$ 的先验分布。

2) 根据式(6)定义 F 。

3) 根据式(8)求得分布 $q(Z_n)$ 和 $q(u_n)$ 并覆盖原 $q(Z_n)$ 、 $q(u_n)$ 。

4) 根据式(8)求分布 $q(\boldsymbol{\mu}_j, \boldsymbol{\Lambda}_j)$ 、 $q(\nu_j)$ 、 $q(\alpha)$ 并覆盖原 $q(\boldsymbol{\mu}_j, \boldsymbol{\Lambda}_j)$ 、 $q(\nu_j)$ 、 $q(\alpha)$ 。

5) 步骤3)和步骤4)不断交替进行。假设当前迭代步数为 s , 若 $F_s - F_{s-1} < \varepsilon$ (ε 为精度参数, 由人为设定), 则收敛完成。输出 $q(Z)$ 、 $q(u)$ 、 $q(\boldsymbol{\mu}, \boldsymbol{\Lambda})$ 、 $q(\alpha)$ 。

2 基于 iSMM 的故障预警方法

机械振动信号与激励源、传递路径间的关系如式(11)所示。

$$Y(t) = \sum_{i=1}^N F_i(t) H_i(t) \quad (11)$$

式中, $Y(t)$ 为 t 时刻测点处的振动信号函数; N 为激励源数; $F_i(t)$ 为第 i 个激励源在 t 时刻激励力函数;

$H_i(t)$ 为 t 时刻第 i 个激励源到测点处的传递函数。

由式(11)知,测点处的振动信号由机械各激励源激发的激励信号叠加形成。当机械运行状态改变,即部分激励力函数、传递函数发生变化,机械振动信号的统计分布也会随之改变。因此,iSMM 拟合机械振动信号所得的统计分布模型能够表征机械的运行状态。基于 iSMM 的机械故障预警方法流程如图 1 所示,包括高维特征空间构建、统计分布模型训练、自适应阈值计算及报警 3 个部分。

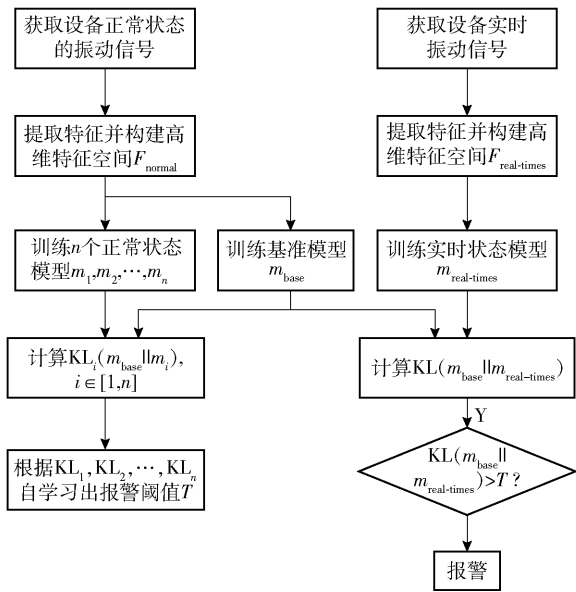


图 1 基于 iSMM 的故障预警流程

Fig. 1 Fault early warning process based on iSMM

2.1 高维特征空间构建

将数采系统在第 i 次采样获取的振动数据特征提取后按时间顺序构成数组,并定义其为 X_i 。利用 X_i 构建高维特征空间 F_i 的过程见式(12)。

本文选用基于降噪自编码器的方法进行特征提取^[12]。将所提特征数量设置为 10;网络结构设定为 $n_i - 1\ 000 - 500 - 10 - 500 - 1\ 000 - n_i$,其中, n_i 表示单组时域信号的维数;神经元激活函数设为 tanh 函数;学习率设为 0.01。

$$X_i \xrightarrow{\text{高特征空间构建}} \begin{bmatrix} f_{1,1} & f_{1,2} & \cdots & f_{1,n} \\ f_{2,1} & f_{2,2} & \cdots & f_{2,n} \\ \vdots & \vdots & \ddots & \vdots \\ f_{m,1} & f_{m,2} & \cdots & f_{m,n} \end{bmatrix} \quad (12)$$

式中, m 为特征类型; n 为特征数量; $f_{j,k}$ 表示第 j 个特征类型中的第 k 个特征。

为避免各类特征的幅值差异对模型训练造成影响,对 F_i 作归一化处理。对 F_i 内的任一元素 $f_{j,k}$ 归

一化的计算方法见式(13)。

$$f_{j,k}^* = \frac{f_{j,k} - \min(f_j)}{\max(f_j) - \min(f_j)} \quad (13)$$

式中, $f_{j,k}^*$ 表示对 $f_{j,k}$ 归一化; $\min(f_j)$ 为 F_i 内所有第 j 类别特征中的最小值; $\max(f_j)$ 为 F_i 内所有第 j 类别特征中的最大值。

2.2 统计分布模型训练

由于小样本易扭曲总体分布形态,为避免此问题,训练统计分布模型所用样本内应包含基于数采系统连续采样构建的多个高维特征空间。样本 S 表示如下。

$$S = [F_1, F_2, \cdots, F_i, \cdots, F_v] \quad (14)$$

式中, v 为样本容量。

利用 1.2 节参数估计算法使 iSMM 拟合样本 S , 可得如式(15)所示的机械状态模型 m 。

$$m = \sum_{i=1}^k \pi_j t(\mu_j, \Lambda_j, \nu_j) \quad (15)$$

式中, k 为 iSMM 根据样本 S 确定的类数即激励数; π_j 表示第 j 个类的权重。

2.3 自适应阈值计算及报警

基于 iSMM 的故障预警方法通过计算机械在正常和实时运行条件下统计分布模型间的距离来定量评估机械当前运行状态,因此如何准确度量模型间距离是确保预警效果的关键。

在计算基准模型与正常状态模型、基准模型与实时状态模型这些统计分布模型间的距离时,基于匹配的 KL 散度近似算法首先对两模型内的子成分进行匹配,然后对每对匹配的子成分计算其 KL 散度、权重比,最后计算出两模型间的距离。由于统计分布模型内的子成分表征的是机械振动信号激励信号的统计分布,利用该度量方法的计算机制可间接实现对机械内各激励信号统计分布变化的识别,并且该算法具有较高的计算精度、计算效率^[13],故采用该算法度量模型间的距离,如式(16)所示。

$$\text{KL}(a \parallel b) = \sum_{i=1}^k \pi_{a,i}(V) \left[\text{KL}(a_i \parallel b_{w(i)}) + \ln \frac{\pi_{a,i}(V)}{\pi_{b,w(i)}(V)} \right] \quad (16)$$

其中,

$$w(i) = \arg\min(\text{KL}(a_i \parallel b_j) - \ln(\pi_{b,j}(V))) \quad (17)$$

式中, $\text{KL}(a_i \parallel b_j)$ 表示模型 a 中第 i 个子成分与模型 b 中第 j 个子成分的 KL 散度,相应算法参考文

献[14]。

在机械历史正常时段下训练出基准状态模型 m_{base} 和 n 个正常状态模型 $m_1, \dots, m_i, \dots, m_n$, 利用上述算法计算 m_{base} 与 m_i 间距离 $\text{KL}_i(m_{\text{base}} \parallel m_i), i \in [1, n]$ 。由于机械在正常运行时状态通常较稳定, 认为各正常状态模型间差异由随机误差造成, 并服从高斯分布。由 3σ 准则可知, 在高斯分布中数值分布在 $(\mu - 3\sigma, \mu + 3\sigma)$ 外的置信度仅占不到 0.3% [15], 对应数值判定为非随机误差造成。

报警决策规则定为统计基准状态模型 m_{base} 与各正常状态模型间的距离 $\text{KL}_i(m_{\text{base}} \parallel m_i), i \in [1, n]$ 。计算这些距离的均值 μ 和标准差 σ 。考虑到实际中 $\mu - 3\sigma$ 存在小于 0 的可能, 并且模型间距离非负, 故将阈值 T 设定为 $\mu + 3\sigma$ 。利用机械实时振动数据来训练实时状态模型 $m_{\text{real-times}}$, 当 $\text{KL}(m_{\text{base}} \parallel m_{\text{real-times}}) > T$ 时, 认为机械状态处于异常, 触发报警。

3 试验验证

3.1 案例数据

以某企业生产现场中的往复压缩机为研究对象, 利用不同结构往复式压缩机出现的活塞组件磨损、气阀泄露和液击 3 种故障案例数据对 iSMM 方法进行测试, 所选故障案例数据详情如表 1 所示。

表 1 故障案例详情		
Table 1 Fault case details		
故障类型	机组结构形式	案例数量
活塞组件磨损	4 缸-M 型	10
	2 缸-D 型	5
气阀泄露	6 缸-M 型	2
	4 缸-M 型	2
	3 缸-D 型	1
	2 缸-D 型	4
液击	2 缸-L 型	1
	2 缸-D 型	2

以 6 缸 M 型结构的往复式压缩机为例, 其传感器布置如图 2 所示。在机组十字头的中体位置上安装压电式加速度传感器, 采样频率设定为 10 kHz; 采样间隔设定为往复式压缩机的两个运转周期。依据生产现场中 SF 方法的报警时间点将故障案例数据划分为正常状态数据和异常状态数据两部分, 并对这两部分数据按照样本容量 v 为 100 进行划分, 将划分余下样本容量不足 100 的样本舍去。在机组正

常状态数据对应生成的样本中, 按时间顺序选取前 10% 样本用于计算报警阈值, 其中选取第一个样本用于训练基准模型, 其余样本用于测试。




图 2 传感器布置示意图
Fig.2 Sensor layout diagram

3.2 试验结果及分析

试验分别从报警准确率和相对 SF 方法报警的提前时间两方面来考察 iSMM 方法的预警效果。此外, 为探究 iSMM 的鲁棒性在故障预警中的作用, 试验中引入基于无限高斯混合模型的故障预警方法 (简称 iGMM 方法)。iGMM 聚类机制与 iSMM 相同, 其区别在于拟合数据时鲁棒性相对较差。试验时对同一样本分别使用 iSMM 和 iGMM 进行拟合, 并分别统计预警结果。

为探究不同样本容量 v 对 iSMM 方法报警准确率的影响, 将 27 组故障案例全部用于测试, 对 iSMM 方法进行 8 次试验, 试验中样本容量 v 由 20 等间隔递增至 160 组, 测试结果见图 3。可以看出, 随着样本容量 v 的增大, iSMM 方法报警准确率随之升高, 但模型训练时耗随之增加; 当样本容量 v 超过 100 时, iSMM 方法报警准确率受样本容量影响较小。因此, 综合考虑预警效果与模型的训练效率, iSMM 方法中样本容量 v 应设定为 100。




图 3 样本容量对 iSMM 方法报警准确率及时耗的影响
Fig.3 The influence of sample size on the alarm accuracy and time consumption of the proposed method

iSMM 方法和 iGMM 方法的试验结果见表 2。由表 2 可知,对于不同结构机组出现的活塞组件磨损、气阀泄露和液击故障,iSMM 方法均实现了报警,相比之下,iGMM 方法未能对 3 缸 D 型机组气阀故障实现报警。

表 2 iSMM 方法及 iGMM 方法的故障预警试验结果

Table 2 The results of the proposed method and iGMM method				
故障类型	机组结构形式	案例数量	实现报警的案例数量	
			iSMM	iGMM
活塞组件磨损	6 缸-M 型	2	2	2
	4 缸-M 型	10	8	8
气阀泄露	2 缸-D 型	5	5	5
	4 缸-M 型	2	2	2
	3 缸-D 型	1	1	0
	2 缸-D 型	4	4	4
液击	2 缸-L 型	1	1	1
	2 缸-D 型	2	2	2

将 iSMM 方法和 iGMM 方法的试验结果进一步统计于表 3。由表 3 可知,iSMM 方法整体具有较高的报警准确率,可达 92.59%;而 iGMM 方法报警准确率为 88.89%。上述结果表明 iSMM 较 iGMM 性能更优,且 iSMM 方法能够较准确地识别出往复式压缩机故障。

表 3 iSMM 方法和 iGMM 方法的报警准确率统计

Table 3 Alarm accuracy statistics of the two methods			
方法	实现报警案例数量	案例总数量	报警准确率/%
iSMM	25	27	92.59
iGMM	24	27	88.89

为进一步评估 iSMM 方法的预警效果,将 iSMM 方法、iGMM 方法较 SF 方法提前的报警时长定义为预警时长,分别计算 iSMM 方法、iGMM 方法相对于 SF 方法对各类型故障的平均预警时长,计算结果见表 4。

表 4 iSMM 方法和 iGMM 方法的平均预警时长统计

Table 4 Statistical results of the average alarm time of the two methods			
方法	平均预警时长/h		
	活塞组件磨损故障	气阀泄漏故障	液击故障
iSMM	78.4	19.3	7.56
iGMM	62.3	17	6.32

由表 4 可知,iSMM 方法和 iGMM 方法均实现了比 SF 方法提前报警,而 iSMM 方法较 iGMM 方法可使报警时间进一步提前;在这 3 类故障中,iSMM 方

法对活塞组件磨损故障最为敏感,平均预警时长可达 78.4 h;而对液击故障预警时长相对最短,平均预警时长为 7.56 h。

针对上述结果,本文对故障案例中结构相对复杂的 6 缸-M 型机组进行具体分析。利用 iSMM 方法和 iGMM 方法对该机组 3 种故障的预警详情分别如图 4~6 所示。




图 4 iSMM 方法和 iGMM 方法对活塞组件磨损故障预警结果

Fig. 4 Early warning results of piston component wear failure

由图 4 和图 5 可知,对于 6 缸-M 型机组出现的活塞组件磨损故障和气阀泄漏故障,iSMM 方法计算出的状态异常指标随时间的变化趋势稳定;iGMM 方法计算出的状态异常指标随时间波动相对较大,且在超过阈值后的一段时间内仍在阈值线上下间波动,导致此方法较难识别出机组的状态变化。分析认为,iGMM 方法计算的状态异常指标波动相对较大是由各个样本内的随机离群点导致,表明 iSMM 方法可有效抵抗随机离群点的干扰,从而保证较好的预警效果。

由图 6 可知,当 SF 方法对 6 缸-M 型机组的液击故障报警时,iSMM 方法和 iGMM 方法计算出的状态异常指标已远超报警阈值。液击故障指液体进入机组气缸后没有在排气过程迅速排除,在被压缩过程中产生瞬间高液压,这种瞬间高液压可在极短时




图5 iSMM方法和iGMM方法对气阀泄露故障的预警结果

Fig. 5 Early warning results of air valve leakage




图6 iSMM方法和iGMM方法对液击故障的预警结果

Fig. 6 Early warning results of liquid-hammer failure

间内对机组的压缩受力件造成损坏。由于该类型故障在发生前征兆不明显, iSMM方法对其故障预警时长较短。分析认为, 该机组在SF方法报警时已发

生液击故障, 而iSMM方法较SF方法可提前7h预警机组的液击故障。

4 结论

(1) 提出一种基于iSMM的机械故障预警方法, 该方法利用iSMM拟合机械振动信号的统计分布, 通过比较机械在正常状态与观测状态下的统计分布模型间距离, 实现了复杂机械在无故障样本条件下的故障预警。

(2) iSMM方法可有效地对往复式压缩机进行故障预警, 且受样本随机离群点干扰的影响相对较小, 具有较高的实际应用价值。

目前仅实现在单一运行工况条件下的机械故障预警, 而未考虑时变工况。今后将考虑利用机械的运行工况识别技术, 并对iSMM方法在相关方面进行改进。

参考文献:

- [1] 张明, 江志农. 基于多源信息融合的往复式压缩机故障诊断方法[J]. 机械工程学报, 2017, 53(23): 46-52.
ZHANG M, JIANG Z N. Reciprocating compressor fault diagnosis technology based on multi-source information fusion [J]. Journal of Mechanical Engineering, 2017, 53(23): 46-52. (in Chinese)
- [2] 马波, 赵祎, 齐良才. 变分自编码器在机械故障预警中的应用[J]. 计算机工程与应用, 2019, 55(12): 245-249.
MA B, ZHAO Y, QI L C. Application of variational auto-encoder in mechanical fault early warning [J]. Computer Engineering and Applications, 2019, 55(12): 245-249. (in Chinese)
- [3] GAI J B, SHEN J X, HU Y F, et al. Research on the fault warning method based on dual-tree complex wavelet transform and BP neural network [C]//2018 Prognostics and System Health Management Conference. Chongqing: IEEE, 2018: 642-646.
- [4] NIU S Y, LIU B W, ZHANG X Y. Research on fault warning of doubly fed wind power generator based on LS-SVM [C]//Proceedings of the 3rd Annual International Conference on Electronics, Electrical Engineering and Information Science. Guangzhou: Atlantis Press, 2017: 158-163.
- [5] ZHAO G Q, ZHANG G H, GE Q Q, et al. Research advances in fault diagnosis and prognostic based on deep learning [C]//2016 Prognostics and System Health Man-

- agement Conference. Chengdu: IEEE, 2016: 1–6.
- [6] CHEN X L, WANG P H, HAO Y S, et al. Evidential KNN-based condition monitoring and early warning method with applications in power plant [J]. *Neurocomputing*, 2018, 315: 18–32.
- [7] ZHANG W, LIU J Z, GAO M M, et al. A fault early warning method for auxiliary equipment based on multivariate state estimation technique and sliding window similarity [J]. *Computers in Industry*, 2019, 107: 67–80.
- [8] TIPPING M E, LAWRENCE N D. Variational inference for student-t models: robust Bayesian interpolation and generalised component analysis [J]. *Neurocomputing*, 2005, 69(1–3): 123–141.
- [9] WANG J B, SHAO W M, SONG Z H. Robust inferential sensor development based on variational Bayesian student's-t mixture regression [J]. *Neurocomputing*, 2019, 369: 11–28.
- [10] WEI X, LI C G. The infinite student's t-mixture for robust modeling [J]. *Signal Processing*, 2012, 92(1): 224–234.
- [11] HEJBLUM B P, ALKHASSIM C, GOTTARDO R, et al. Sequential dirichlet process mixtures of multivariate skew t-distributions for model-based clustering of flow cytometry data [J]. *The Annals of Applied Statistics*, 2017, 13(1): 638–660.
- [12] BENGIO Y, COURVILLE A, VINCENT P. Representation learning: a review and new perspectives [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(8): 1798–1828.
- [13] GOLDBERGER J, GORDON S, GREENSPAN H. An efficient image similarity measure based on approximations of KL-divergence between two Gaussian mixtures [C] // *Proceedings of the Ninth International Conference on Computer Vision*. Nice: IEEE, 2003: 487–493.
- [14] 白鹏. 两个一元 t-分布之间的 Kullback–Leibler 距离 [J]. *数学物理学报*, 2002, 22(1): 121–127.
BAI P. Kullback–Leibler divergence between two univariate t-distributions [J]. *Acta Mathematica Scientia*, 2002, 22(1): 121–127. (in Chinese)
- [15] 周雁冰, 柳亦兵, 王峰, 等. 齿轮故障振动信号非高斯性特征趋势分析 [J]. *振动与冲击*, 2014, 33(6): 165–169.
ZHOU Y B, LIU Y B, WANG F, et al. Trend analysis of non-Gaussian characteristic for gear fault vibration signals [J]. *Journal of Vibration and Shock*, 2014, 33(6): 165–169. (in Chinese)

A mechanical fault early warning method based on infinite student's t-mixture model clustering

MA Bo^{1, 2} SU FangJian¹ ZHAO Yi³ CAI WeiDong¹

(1. College of Mechanical and Electrical Engineering, Beijing University of Chemical Technology, Beijing 100029;

2. Beijing Key Laboratory for Health Monitoring and Self-Recovery of High-End Mechanical Equipment,

Beijing University of Chemical Technology, Beijing 100029;

3. Shanghai Aircraft Design and Research Institute, Commercial Aircraft Corporation of China Ltd., Shanghai 201210, China)

Abstract: Due to the non-stationary characteristics of the vibration signals of complex machinery such as reciprocating compressors and gas turbines, the signal feature threshold alarm method has low alarm accuracy. In order to solve this problem, a fault early warning method based on the infinite student's t-mixture model (iSMM) is proposed. The proposed method first uses iSMM trained by a high-dimensional feature space which is based on the mechanical vibration signal features to describe the change in performance of the equipment. Secondly, the divergence between the normal condition model and the real-time working model is calculated by matching based on approximating KL divergence. Finally, real-time fault early warning for the mechanical equipment is realized by comparing the divergence with the early warning threshold calculated based on the 3σ rule of thumb. The proposed method has been validated by using actual failure case data for a reciprocating compressor. The results show that this method has high alarm accuracy and good timeliness. The proposed method can provide effective mechanical fault early warning.

Key words: fault early warning; mechanical equipment; infinite student's t-mixture model; unsupervised learning