

# 基于多尺度振动和振声频谱特征自适应提取与选择的磨机负荷参数软测量

刘卓<sup>1</sup>, 柴天佑<sup>1</sup>, 汤健<sup>2,3†</sup>

(1. 东北大学 流程工业综合自动化国家重点实验室, 沈阳 110004; 2. 北京工业大学 信息学部, 北京 100124; 3. 北京市计算智能与智能系统重点实验室, 北京 100124)

**摘要:** 针对磨机筒体振动/振声多尺度频谱与磨机负荷参数间的模糊特性、多源多尺度频谱间的冗余性与互补性, 以及现有文献中潜结构选择性集成模型难以模拟运行专家“听音”推理识别磨机负荷参数等问题, 提出一种基于多尺度振动/振声频谱特征自适应提取与选择的磨机负荷参数软测量模型. 该方法首先进行多尺度频谱获取, 然后基于核潜结构映射和互信息进行多尺度振动和振声频谱特征的自适应提取和选择, 最后采用同步聚类算法、Madani 模糊模型以及基于分支定界和自适应加权融合算法的选择性集成学习策略构建磨机负荷参数软测量模型. 通过实验球磨机验证了所构建的软测量模型能够模拟运行专家的模糊推理机制, 具有较好的建模精度.

**关键词:** 磨机负荷; 经验模态分解; 多尺度频谱; 特征选择与提取; 模糊推理; 选择性集成建模

中图分类号: TP273

文献标志码: A

## Soft sensing modeling of mill load parameter based on adaptive feature selection and extraction of multi-scale vibration and acoustic frequency spectrum

LIU Zhuo<sup>1</sup>, CHAI Tian-you<sup>1</sup>, TANG Jian<sup>2,3†</sup>

(1. State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University, Shenyang 110004, China; 2. Faculty of Information Technology, Beijing University of Technology, Beijing 100124, China; 3. Beijing Key Laboratory of Computational Intelligence and Intelligent System, Beijing 100124, China)

**Abstract:** Aiming at the fuzzy type characteristics between multi-frequency spectrums of vibration/acoustic signal and mill load parameters, the redundancy and complementarity in the multi-frequency spectrums, and the difficulty of using latent structural selected model in existing literatures to simulate the operation expert “listen” inference to identify the mill load parameters, a soft sensing model of mill load parameters based on adaptive extraction and selection of multi-scale vibration/acoustic spectrum characteristics is proposed. The method firstly acquires multi-scale spectrum, then extracts and selects the features of multi-scale vibration and acoustic spectrum adaptively using kernel partial least squares (KPLS) and mutual information (MI). Finally, the soft sensing model of mill load parameters is constructed by using online clustering, Madani fuzzy model, banch and bound (BB), adaptation weighted fusion (AWF) and modeling of selective sets. The experiments are carried out in the experimental wet mill. The experimental results show that the proposed model can simulate the expert’s reasoning mechanism and has better modeling accuracy.

**Keywords:** mill load; emprical mode decomposition (EMD); multi-scale frequency spectrum; feature selection and extraction; fuzzy inference; selective ensemble modeling

## 0 引言

磨矿过程是选矿生产过程的“瓶颈”作业,其作用是将破碎后的原矿通过大型旋转机械设备(球磨机)研磨成粒度合格的矿浆,为后续选矿过程提供原

料. 准确检测磨机负荷是实现磨矿过程优化控制和节能降耗的关键. 工业界通常采用磨机研磨过程中产生的机械振动/振声及磨机电流等多源信号对磨机负荷进行间接测量<sup>[1]</sup>. 运行专家依据人耳辨别的振声

收稿日期: 2018-03-28; 修回日期: 2018-05-29.

基金项目: 国家自然科学基金项目(61703089, 61673097, 61573364, 61473071); 中央高校基本科研业务费专项资金项目(N170804005).

责任编辑: 柴利.

†通讯作者. E-mail: tjian001@126.com.

“清脆”、“沉闷”等模糊特性,凭经验推理识别磨机负荷的“偏高”、“适中”、“偏低”等模糊性状态,这是基于人类专家经验进行不确定性推理的选择性信息的融合过程.如何基于现有技术对运行专家的“听音识别”过程进行模拟是本文的主要关注点.

采用信号处理、机器学习等多个学科领域的研究成果是开展磨机负荷检测研究的有效手段<sup>[2]</sup>.快速傅里叶变换(FFT)不适合具有非稳态特性的机械振动和振声信号的处理<sup>[3]</sup>.离散小波变换、连续小波变换(CWT)、小波包变换等时频分析方法已广泛地用于旋转机械设备的故障诊断<sup>[4-7]</sup>,但这些方法不能自适应分解本文所面对的多组分机械振动和振声信号.经验模态分解(EMD)技术通过自适应分解获取具有不同时间尺度的内禀模态函数(IMFs)<sup>[8]</sup>,可以有效地将筒体振动信号分解为系列具有不同带宽的多尺度信号<sup>[9]</sup>,可用于模拟人耳的“带通滤波”能力.文献[10-11]进行了基于IMF和FFT技术的机械设备故障诊断和磨机筒体振动分析;文献[12]构建了基于EMD的选择性集成(SEN)模型,但建模精度较低;文献[13]在建模精度上有所提高,但没有开展频谱特征的自适应提取与选择,没有从运行专家“听音识别”的角度进行考虑.集成EMD(EEMD)技术克服了EMD方法的模态混合问题<sup>[14]</sup>,但有价值的IMF的数量仍是有限的.基于偏最小二乘或潜变量映射(PLS)的特征提取方法可以提取同时表征输入输出数据变化的潜在变量,将难以进行规则提取的多尺度频谱进行有效维数约简<sup>[15]</sup>,从而模拟人脑的“特征抽取”能力.

优秀运行专家“听音识别”利用的是经磨机研磨区域筒体振动辐射产生的振声信号.该信号源于筒体,并且夹杂着周围其他机械设备的背景噪声,灵敏度和可靠性低于磨机筒体振动信号,但运行专家难以提取筒体振动信号推理规则.文献[16]提出了从数据中挖掘模糊规则的高效率算法,模糊规则的可解

释性和透明性也增加了推理模型的可理解性.通常,模糊规则的提取过程被称为结构辨识.很多离线和在线的聚类策略,如模糊C-均值、爬山聚类、减法聚类、递推在线聚类,用于模糊规则的提取,但是这些算法策略未考虑输入与输出数据空间存在的相互关系.文献[17]通过引入新设计的参数对输入空间进行加权,有效地解决了这一问题.针对磨矿过程湿式工业球磨机,文献[18]基于磨机电流和过程变量提出了采用规则推理的磨机过负荷智能监测与控制;基于轴承振动和磨机电流,文献[19]提出了采用数据融合与案例推理估计磨机负荷;文献[20]提出了基于实验磨机筒体振动多尺度频谱的磨机负荷参数模糊推理选择性集成建模方法.上述方法均未基于模拟运行专家“听音”推理识别过程进行磨机负荷软测量,也不能利用高灵敏度磨机筒体振动信号,难以实现较为准确的磨机负荷检测.研究表明,优选可用的子模型进行SEN能够得到比简单集成全部子模型以及单一模型更佳泛化性能<sup>[21]</sup>.因此,选择性地优化集成多个模糊推理模型可以获得更好的预测性能.

综上,本文提出一种模拟“人脑识别”过程的具有多层结构的基于模糊推理的磨机负荷参数选择性集成模型软测量方法.实验结果表明,该软测量模型能够模拟运行专家的模糊推理机制,具有较好的建模精度.

## 1 基于多尺度振动和振声频谱特征自适应提取与选择的磨机负荷参数软测量建模策略

多尺度振动和振声频谱特征的磨机负荷参数软测量建模策略,由多尺度振动/振声频谱转换模块、潜在特征自适应提取与选择模块、基于多尺度振动和振声频谱有价值特征的模糊推理集成建模模块这3部分组成,如图1所示.

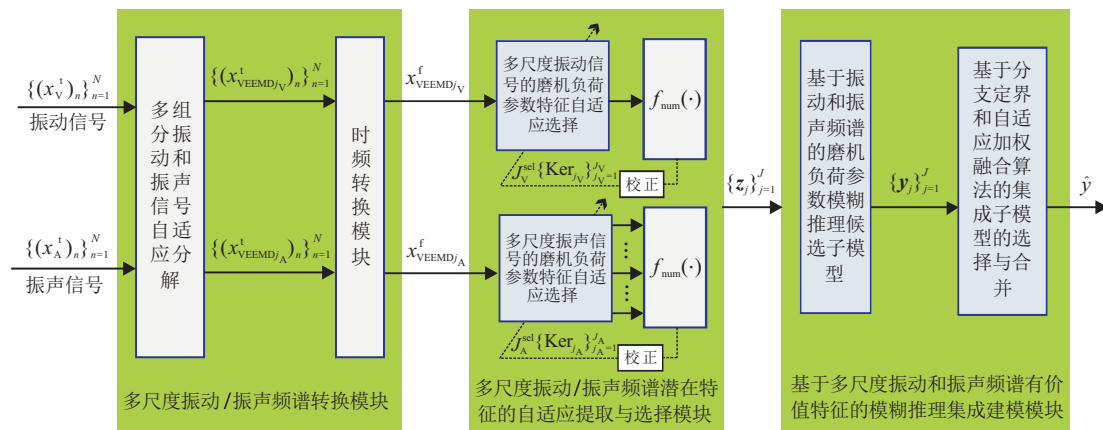


图1 基于多尺度振动和振声频谱特征自适应提取与选择的磨机负荷参数软测量建模策略

图1中:  $\mathbf{X}_V^t = \{(X_V^t)_n\}_{n=1}^N$  和  $\mathbf{X}_A^t = \{(X_A^t)_n\}_{n=1}^N$  分别表示时域筒体振动和振声信号;  $\mathbf{X}_{VEEMD_{j_V}}^t$  和  $\mathbf{X}_{VEEMD_{j_A}}^t$  分别表示第  $j_V$  和第  $j_A$  个筒体振动和振声的 IMF 子信号;  $\mathbf{X}_{VEEMD_{j_V}}^f$  和  $\mathbf{X}_{VEEMD_{j_A}}^f$  表示时频转换后得到的频域筒体振动和振声信号;  $J_V^{sel}$  和  $J_A^{sel}$  表示采用核偏最小二乘 (KPLS) 与互信息 (MI) 相结合的  $f_{num}(\cdot)$  准则选择的有价值的振动和振声 IMF 子信号的数量;  $\{\text{Ker}_{j_V}\}_{j_V=1}^{J_V}$  和  $\{\text{Ker}_{j_A}\}_{j_A=1}^{J_A}$  表示用于提取与选择振动和振声频谱的潜在特征所采用的核参数;  $\{z_j\}_{j=1}^J$  表示最终所提取与选择的全部潜在特征子集, 其中  $z_j$  表示针对第  $j$  个有价值的 IMF 所提取与选择的潜在特征,  $J$  表示所选择的用于构建候选模糊推理子模型的价值子信号的数量;  $\{y_j\}_{j=1}^J$  表示基于  $z_j$  所构建的第  $j$  个候选模糊推理子模型的输出;  $\hat{y}$  表示最终的选择性集成模糊推理模型的输出。

该策略中不同模块的功能如下。

1) 多尺度振动/振声频谱转换模块: 采用 EEMD 算法将预处理后的筒体振动和振声信号自适应分解为具有不同时间尺度的 IMF, 并采用 FFT 技术将这些子信号变换为多尺度频谱。

2) 多尺度振动/振声频谱潜在特征的自适应提取与选择模块: 采用 KPLS 算法提取多尺度频谱的潜在特征, 结合 MI 度量不同子信号的频谱潜在特征的贡献率, 再依据设定的阈值自适应选择 KPLS 的核参数, 最终提取与选择不同 IMF 的潜在特征。

3) 基于多尺度振动和振声频谱有价值特征的模糊推理集成建模模块: 采用同步聚类 and Madani 模糊算法构建候选模糊推理子模型, 采用分支定界 (BB) 优化算法和自适应加权融合 (AWF) 算法选择并加权集成模糊推理子模型, 从而获得最终磨机负荷参数选择性集成模糊推理模型。

## 2 基于多尺度振动和振声频谱特征的磨机负荷参数软测量算法

### 2.1 多尺度振动/振声频谱转换算法

采用 EEMD 技术对振动和振声信号进行分解, 分解过程可用下式表示:

$$\mathbf{X}_V^t = \{(x_V^t)_n\}_{n=1}^N \Rightarrow \begin{cases} \mathbf{X}_{VEEMD_{j_1}}^t = \{(X_{VEEMD_{j_1}}^t)_n\}_{n=1}^N, \\ \vdots \\ \mathbf{X}_{VEEMD_{j_V}}^t = \{(X_{VEEMD_{j_V}}^t)_n\}_{n=1}^N, \\ \vdots \\ \mathbf{X}_{VEEMD_{J_V}}^t = \{(X_{VEEMD_{J_V}}^t)_n\}_{n=1}^N; \end{cases} \quad (1)$$

$$\mathbf{X}_A^t = \{(x_A^t)_n\}_{n=1}^N \Rightarrow$$

$$\begin{cases} \mathbf{X}_{AEEMD_{j_1}}^t = \{(X_{AEEMD_{j_1}}^t)_n\}_{n=1}^N, \\ \vdots \\ \mathbf{X}_{AEEMD_{j_A}}^t = \{(X_{VEEMD_{j_A}}^t)_n\}_{n=1}^N, \\ \vdots \\ \mathbf{X}_{AEEMD_{J_A}}^t = \{(X_{VEEMD_{J_A}}^t)_n\}_{n=1}^N. \end{cases} \quad (2)$$

其中  $\mathbf{X}_{VEEMD_{j_V}}^t$  表示第  $m$  个 EMD 分解的第  $j_V$  个 IMF。

这些分解的信号按照频率由高到低依次排列。由于有价值信息难以在时域内提取, 进行频域分析是非常必要的。每个 IMF 均采用 FFT 变换到频域, 得到振动和振声频谱, IMF 的时域与频域间的转换可用下式表示:

$$\begin{cases} \vdots \\ \mathbf{X}_{VEEMD_{j_V}}^t \xrightarrow{\text{FFT}} \mathbf{X}_{VEEMD_{j_V}}^f, \\ \mathbf{X}_{AEEMD_{j_A}}^t \xrightarrow{\text{FFT}} \mathbf{X}_{AEEMD_{j_A}}^f, \\ \vdots \end{cases} \quad (3)$$

虽然不同 IMF 信号具有不同的带宽, 但在分辨率为 1 Hz 时, 高频段频谱的数量仍然高达数千维。

### 2.2 多尺度振动和振声频谱潜在特征自适应提取与选择算法

采用 KPLS 算法对经过上述转换得到的振动和振声的 IMF 频谱进行特征提取。为了在给定的候选核参数范围  $[\text{Ker}_{\min}, \dots, \text{Ker}_{\max}]$  内优化选择  $\text{Ker}_{j_V}$ , 此处定义综合指标  $\delta_{j_V}^{\text{Ker}_{j_V}}$  为

$$\delta_{j_V}^{\text{Ker}_{j_V}} = \sum_{p_{j_V}=1}^{h_{sel}} (\delta_{j_V}^{\text{Ker}_{j_V}})_{p_{j_V}} = \sum_{p_{j_V}=1}^{h_{sel}} \{(\delta_{j_V}^{\text{Ker}_{j_V}})_{p_{j_V}} \times \text{MI}(\mathbf{y}; (z_{j_V})_{p_{j_V}})\}_{p_{j_V}}. \quad (4)$$

其中:  $(\delta_{j_V}^{\text{Ker}_{j_V}})_{p_{j_V}}$  是采用核参数  $\text{Ker}_{j_V}$  时第  $p_{j_V}$  个潜在特征的方差百分比;  $\text{MI}(\mathbf{y}; (z_{j_V})_{p_{j_V}})$  是第  $p_{j_V}$  个潜在特征  $(z_{j_V})_{p_{j_V}}$  与磨机负荷参数  $\mathbf{y}$  间的互信息值, 采用下式进行计算:

$$\text{MI}(\mathbf{y}; (z_{j_V})_{p_{j_V}}) = \iint p(\mathbf{y}, (z_{j_V})_{p_{j_V}}) \log \frac{p(\mathbf{y}, (z_{j_V})_{p_{j_V}})}{p((z_{j_V})_{p_{j_V}})p(\mathbf{y})} d((z_{j_V})_{p_{j_V}}) d\mathbf{y} = H(\mathbf{y}) - H(\mathbf{y}|(z_{j_V})_{p_{j_V}}). \quad (5)$$

$p((z_{j_V})_{p_{j_V}})$  和  $p(\mathbf{y})$  是  $(z_{j_V})_{p_{j_V}}$  和  $\mathbf{y}$  的边际概率密度,  $p(\mathbf{y}, (z_{j_V})_{p_{j_V}})$  是联合概率密度,  $H(\mathbf{y}|(z_{j_V})_{p_{j_V}})$  是条件熵,  $H((z_{j_V})_{p_{j_V}})$  是信息熵。

用于潜在特征提取的核参数  $\text{Ker}_{j_V}$  采用下式进

行选择:

$$\begin{aligned} \text{Ker}_j &= \max\{\delta_{jV}^{\text{Ker}_{jV}}\}; \\ \text{s.t.} \quad &\begin{cases} \delta_{jV}^{\text{Ker}_{jV}} = \sum_{p_{jV}}^{h_{\text{sel}}} (\delta_{jV}^{\text{Ker}_{jV}})_{p_{jV}}, \\ \text{Ker}_{jV} \in [\text{Ker}_{\min}, \dots, \text{Ker}_{\max}]. \end{cases} \end{aligned} \quad (6)$$

其中指标  $\delta_{jV}^{\text{Ker}_{jV}}$  用于评估第  $j_V$  个 IMF 在采用核参数  $\text{Ker}_{jV}$  时的价值. 进一步, 通过预设定阈值  $\theta_\delta$ , 采用如下准则进行有价值 IMF 子信号的判别:

$$\zeta_{jV} = \begin{cases} 1, & \delta_{jV}^{\text{Ker}_{jV}} > \theta_\delta; \\ 0, & \delta_{jV}^{\text{Ker}_{jV}} < \theta_\delta. \end{cases} \quad (7)$$

将  $\zeta_{jV} = 1$  的 IMFs 选择为有价值的子信号. 将被选择的 IMFs 的数量记为  $J_V^{\text{sel}}$ , 对多尺度振声频谱利用相同方式处理. 将这些被选择的筒体振动和振声信号的 IMFs 频谱潜在特征作为训练子集.

将所提取的磨机筒体振动和振声多尺度潜在特征进行统一编号, 如下式所示:

$$\begin{aligned} \mathbf{Z} &= [\mathbf{Z}_{1V}, \dots, \mathbf{Z}_{jV}^{\text{sel}}, \dots, \mathbf{Z}_{jV}^{\text{sel}}, \mathbf{Z}_{1A}, \dots, \mathbf{Z}_{jA}^{\text{sel}}, \mathbf{Z}_{jA}^{\text{sel}}] = \\ &[\mathbf{Z}_1, \dots, \mathbf{Z}_j, \dots, \mathbf{Z}_J] = \{z_j\}_{j=1}^J. \end{aligned} \quad (8)$$

其中:  $J = J_V^{\text{sel}} + J_A^{\text{sel}}$ , 表示选择的 IMF 子信号数量; 假定  $\mathbf{Z}_j$  中包含的潜在特征数量为  $h'$ , 其本质是基于某个被选择的 IMF 子信号频谱提取的潜在特征.

### 2.3 选择性集成模糊推理模型算法

#### 2.3.1 候选模糊推理子模型的构建

构建候选子模型的模糊推理规则, 如下式所示:

$$\begin{aligned} \text{rule } g: & \text{ if } z_j \text{ is } A^g \text{ and, } \dots, \text{ and } z_{jh'} \text{ is } C^g, \\ & \text{ then } y \text{ is } D^g. \end{aligned} \quad (9)$$

其中:  $g = 1, 2, \dots, G$ ,  $G$  为规则的数目, 采用同步聚类方法确定;  $A^g$ 、 $C^g$ 、 $D^g$  的隶属度函数分别为  $\gamma_{A^g}$ 、 $\gamma_{C^g}$ 、 $\gamma_{D^g}$ .

采用产生式规则推理、单点模糊化和重心法解模糊后, 候选模糊推理子模型输出由下式计算<sup>[17]</sup>:

$$\hat{y}_j = \left( \sum_{g=1}^G W_g [\gamma_{A^g}, \dots, \gamma_{C^g}] \right) / \left( \sum_{g=1}^G [\gamma_{A^g}, \dots, \gamma_{C^g}] \right). \quad (10)$$

其中:  $\hat{y}_j$  为第  $j$  个候选模糊推理模型的输出,  $W_g$  为  $\gamma_{D^g} = 1$  的  $\hat{y}_j$  点.

采用同步聚类方法确定隶属函数和模糊规则数, 算法步骤如下.

#### 算法1 同步聚类算法.

Step 1: 对于第 1 组数据  $G_1$ ,  $k = 1$ ,  $u(1)$  为第 1 个聚类的中心, 即存在:  $z_i^1 = z_i(1)$ ,  $\bar{y}^1 = y(1)$ ,  $l_1^g =$

$l_2^g = 1$ .

Step 2: 如果新的一组数据加入聚类, 即  $l_2^g = l_2^g + 1$ , 则计算  $d_k$ ; 如果没有新的数据进行聚类, 则转向 Step 5.

Step 3: 如果  $d_k \leq L$ , 则  $u(k)$  仍属于聚类  $G_g$ , 转向 Step 2.

Step 4: 如果  $d_k > L$ , 则由  $u(k)$  产生一个新的类, 有  $g = g + 1$ ,  $n = n + 1$ , 聚类  $G_j$  的中心为  $\bar{u}_i^j = u(k)$ ,  $l_1^g = l_2^g = k$ , 转向 Step 2.

Step 5: 重新比较所有聚类中心  $\bar{u}^g$  之间的距离, 如果  $d_k \leq L$ , 则两类合并为一个聚类.

算法 1 中:  $u(k) = [z_1(k), z_2(k), z_3(k), y(k)]$  表示在  $k$  时刻的新的数据点;  $d_k$  表示在该时刻的欧拉距离;  $L$  为产生新规则的阈值, 即将两个聚类目标聚成一个类所需要的相似度的最小可能取值.

隶属度函数选取为以下的高斯函数:

$$\gamma_{q^j} = \exp \left[ - \left( \frac{z_i - \bar{q}^g}{\delta_q^g} \right)^2 \right]. \quad (11)$$

高斯函数的宽度按下式选择:

$$\delta_q^g = \frac{\sigma_{\max}}{\sqrt{8 \log 2}}. \quad (12)$$

其中:  $q = A, \dots, D$ ,  $\sigma_{\max} = L/2$ .

经过同步聚类, 每个类对应一条模糊规则, 每个类的中心分别为  $\bar{A}^g$ 、 $\bar{B}^g$ 、 $\bar{C}^g$ , 而模糊规则的总数  $G$  为模糊聚类的个数.

#### 2.3.2 集成子模型的选择与合并

在集成模型结构和子模型集成方法确定的情况下, 选择性集成建模的实质是优选子模型的过程.

选择性集成模型的输出值为

$$\hat{y} = \sum_{j_{\text{sel}}=1}^{J_{\text{sel}}} w_{j_{\text{sel}}} \hat{y}_{j_{\text{sel}}}. \quad (13)$$

其中:  $\hat{y}_{j_{\text{sel}}}$  表示基于第  $j_{\text{sel}}$  训练子集建立的模型的输出;  $w_{j_{\text{sel}}}$  由下式表示:

$$w_{j_{\text{sel}}} = 1 / \left( (\sigma_{j_{\text{sel}}})^2 \sum_{j_{\text{sel}}=1}^{J_{\text{sel}}} \frac{1}{(\sigma_{j_{\text{sel}}})^2} \right). \quad (14)$$

这里:  $\sum_{j_{\text{sel}}=1}^{J_{\text{sel}}} w_{j_{\text{sel}}} = 1$ ,  $0 \leq w_{j_{\text{sel}}} \leq 1$ ,  $w_{j_{\text{sel}}}$  是基于第  $j$  个有价值的 IMF 所提取和选择的潜在特征建立的子模型所对应的加权系数;  $\sigma_{j_{\text{sel}}}$  为子模型输出值  $\{\hat{y}_{j_{\text{sel}}}^l\}$  ( $l = 1, 2, \dots, k$ ) 的标准差,  $k$  为样本个数;  $j_{\text{sel}} = 1, 2, \dots, J_{\text{sel}}$ ,  $J_{\text{sel}}$  是选择的集成子模型的个数.

本文采用多次运行 BB 和 AWF 算法的方式实现最优子模型的选择<sup>[22]</sup>: 首先分别确定子模型个数为 2, 3,  $\dots$ ,  $(J - 1)$  时的最优选择性集成模型; 然后将这些选择性集成模型进行排序, 依据建模精度选择最

终的磨机负荷参数软测量模型. 基于BB和AWF的选择性集成模糊模型算法步骤如下.

**算法2** 基于BB和AWF的选择性集成模糊模型算法.

Step 1: 建立  $J$  个候选模糊集成子模型.

Step 2: 设定选择的子模型的数量  $J_{\text{sel}} = 2$ .

Step 3: 结合BB和AWF算法选择包含  $J_{\text{sel}}$  个子模型的最优选择性集成模型.

Step 4: 令  $j_{\text{sel}} = J_{\text{sel}} + 1$ .

Step 5: 若  $J_{\text{sel}} = J - 1$ , 则转 Step 6; 否则, 转 Step 3.

Step 6: 排序  $(J - 2)$  个选择性集成模型, 确定最终集成模型.

### 3 实验研究

#### 3.1 数据描述

实验在 XMQL 420×450 格子型球磨机上进行, 其筒体的外径和长度均为 460 mm. 由功率为 2.12 kW

的三相电机驱动, 最大钢球装载量为 80 kg, 设计磨粉能力为 10 kg/h, 转速为 57 n/min. 磨机中部开口, 用于添加钢球、物料和水负荷. 实验中采用的物料为铜矿石, 直径均小于 6 mm, 密度为 4.2 t/m<sup>3</sup>. 采用直径为 30、20 和 15 mm 的钢球作为研磨介质, 配比为 3:4:3. 其中: 筒体振动信号的采集频率是 51 200 Hz, 振声信号的采集频率是 8 000 Hz.

#### 3.2 实验结果及分析

##### 3.2.1 多尺度振动/振声频谱分解及转换结果

首先采用  $A_{\text{noise}} = 0.1$  和  $M = 10$ , 基于 EEMD 技术将磨机旋转 4 个周期的原始筒体振动和振声信号分解为多时间尺度子信号; 然后, 将这些具有不同时间尺度的 IMFs 利用 FFT 变换为多尺度频谱. 前 8 个筒体振动子信号 (VIMF) 和振声子信号 (AIMF) 的频谱如图 2 所示.

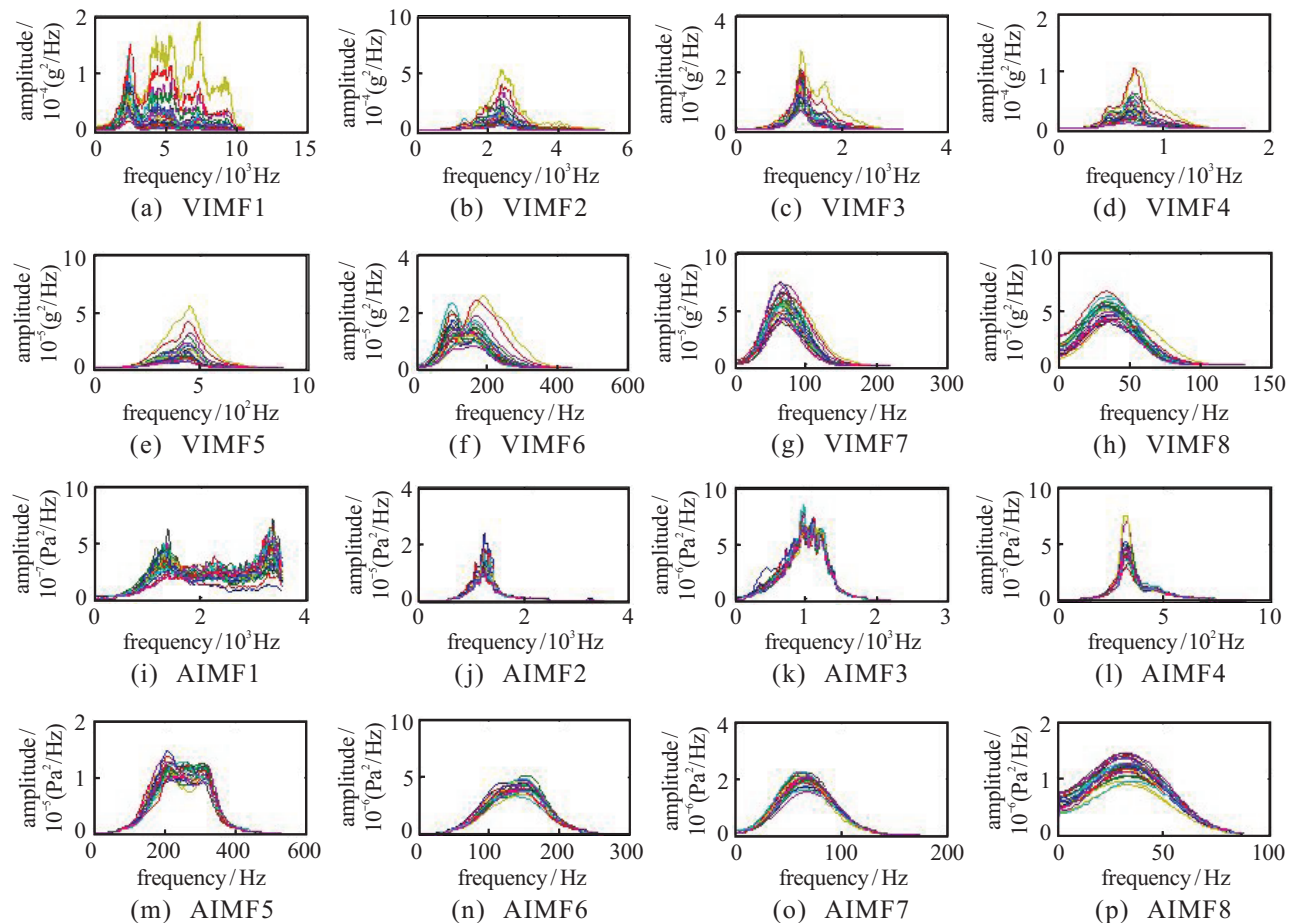


图 2 筒体振动和振声信号的前 8 个 IMFs 的频谱

图 2 表明, 从频谱形状看, 这些多组分子信号经过 EEMD 分解和 FFT 转换后, 得到的多尺度频谱按照频率由高到低的顺序依次排列. 由于这些多尺度频谱仍然具有高维共线性的特点, 在构建软测量模型前需要进行维数约简和共线性处理.

##### 3.2.2 多尺度振动/振声频谱潜在特征自适应提取与选择结果

针对本文所采用的基于 KPLS 的特征提取方法, 为不同的多尺度频谱选择相同的径向基函数 (RBF) 作为核函数. 基于先验知识, RBF 的候选核半

径为0.1, 1, 10, 100和1 000. 基于KPLS提取潜在核特征, 通过MI算法计算这些特征与磨机负荷参数间相关性的强弱. 下面将以3个不同的磨机负荷参数(MBVR为料球比、PD为磨矿浓度、CVR为充填率)中的MBVR为例, 对其选择的多尺度频谱过程进行

详细描述.

针对磨机负荷参数MBVR, 取不同径向基函数(RBF)半径时, 以振动信号为例, 前10个IMFs(按照分解结果从高到低依次定义为IMF1~IMF10)的最大PV值、MI值和综合指标值如表1所示.

表1 筒体振动前10个IMFs基于KPLS提取的潜在特征的最大PV值、MI值和综合指标值

$K_{para}$	指标	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6	IMF7	IMF8	IMF9	IMF10
0.1	PV值/%	37.81	47.10	34.87	35.35	32.05	44.16	26.24	21.18	20.74	38.88
	MI值	0.453 7	0.513 2	0.620 6	0.617 7	0.503 6	0.443 3	0.408 0	0.579 8	0.514 7	0.287 7
	综合指标值	31.21	36.23	39.62	41.02	36.73	31.10	22.97	26.82	25.27	21.97
1	PV值/%	66.98	61.35	53.16	60.49	70.64	68.2	34.02	32.36	43.56	69.39
	MI值	0.338 1	0.516 4	0.535 6	0.590 4	0.442 7	0.411 7	0.326 4	0.503 9	0.361 7	0.225 5
	综合指标值	30.22	42.39	39.41	48.75	37.87	29.50	24.50	29.52	27.82	20.11
10	PV值/%	92.73	91.48	83.84	86.12	72.29	77.84	43.93	57.06	60.44	73.73
	MI值	0.411 0	0.467 8	0.376 5	0.393 8	0.317 0	0.321 8	0.347 1	0.450 2	0.368 8	0.241 1
	综合指标值	32.27	36.04	35.65	30.43	30.41	28.38	27.53	35.21	29.96	23.26
100	PV值/%	98.35		98.15	95.21	96.54	86.88	79.54	56.04	57.08	61.27
	MI值	0.423 4	0.710 9	0.431 7	0.545 7	0.411 8	0.302 9	0.293 4	0.423 6	0.320 2	0.283 8
	综合指标值	32.98	37.92	32.76	29.39	29.41	27.53	26.81	36.45	30.10	19.26
1 000	PV值/%	98.60	98.44	95.80	97.09	88.58	84.96	64.26	59.84	69.43	64.44
	MI值	0.527 3	0.423 7	0.502 7	0.550 6	0.411 8	0.299 3	0.296 1	0.402 2	0.334 9	0.238 1
	综合指标值	33.24	37.48	30.61	29.82	30.70	26.83	27.53	36.56	32.25	19.31

由表1可知: 核参数越大, 与MBVR相关的频谱特征的方差贡献率越高; 不同IMFs的互信息最大值与不同的核参数相关; 不同IMFs的综合指标与不同的核半径相关. 因此, 可以为不同IMFs选择不同的核

半径.

采用同样方法进行其他两个磨机负荷参数PD和CVR的实验. 3个磨机负荷参数振动/振声频谱的IMF1~IMF10依据综合指标值的排序如表2所示.

表2 不同磨机负荷参数的IMF1~IMF10依据综合指标值的排序

参数	信号类别	指标	按综合指标值由高到低 IMF 的排序									
MBVR	振动	排序	4	2	3	5	8	1	9	6	7	10
		核参	1	1	0.1	1	1000	1000	1000	0.1	10	10
		指标值	48.75	42.39	39.62	37.87	36.56	33.24	32.25	31.10	27.53	23.26
	振声	排序	9	5	10	8	6	7	1	2	4	3
		核参	1000	10	10	1000	1000	1000	1	1	1	1000
		指标值	99.42	96.74	90.75	89.72	85.37	82.34	70.70	69.52	65.66	64.97
PD	振动	排序	1	4	5	2	6	3	7	8	9	10
		核参	1000	10	10	10	10	1000	100	1000	1000	1000
		指标值	78.81	68.94	68.83	65.87	59.81	55.09	53.62	39.44	28.76	26.63
	振声	排序	9	6	4	7	1	5	3	2	8	10
		核参	1000	10	100	1000	1	100	1	1	1	0.1
		指标值	93.00	85.30	79.57	75.18	74.92	73.78	69.16	64.07	62.42	57.69
CVR	振动	排序	1	4	5	2	6	3	7	8	9	10
		核参	1000	1000	100	10	1000	1	1000	1000	1000	1000
		指标值	71.49	63.92	63.69	60.17	57.93	56.81	48.13	37.29	32.22	26.01
	振声	排序	1	3	4	5	9	7	8	2	10	6
		核参	1000	100	1000	10	10	1	1	1	0.1	10
		指标值	104.7	90.54	85.73	83.65	76.08	75.79	72.98	72.38	70.10	64.25

表2数据表明, 不同的磨机负荷参数与不同的多尺度频谱的相关性存在差异性, 需要依据相关性的强弱开展频谱特征的自适应提取与选择. 对于MBVR、

PD和CVR中的任何一个磨机负荷参数, 振声多尺度频谱的综合指标值均高于筒体振动. 筒体振动对IMFs选择的大多是前面几个; 振声针对MBVR和PD

选择了后面的几个IMFs,采用互信息和潜在变量贡献率相结合的度量方法,将每个磨机负荷参数选出综合指标值最高的IMF用于建模。

需要说明的是,在选择相对重要的IMFs后,还需要从构建模糊推理模型的视角进行二次优选。

### 3.2.3 模糊推理集成建模结果

通过开展产生新规则的阈值 $L$ 与模型训练和测试误差的仿真实验,确定模糊推理子模型的模型参数:KLV数量为4、阈值 $L$ 为0.69,构建全部候选模糊推理子模型。

依据构建的候选子模型的性能,开展集成尺寸分别为2~10时,磨机负荷参数MBVR选择性集成模糊推理模型的建模误差及选择的集成子模型仿真实验研究,确定选择最佳集成尺寸为3.此时,选择的集成子模型对应的信号为VIMF8、VIMF1和VIMF2。

本文所提出的选择性集成模糊推理模型(BBSEN-fuzzy)、最佳模糊推理子模型(sub-fuzzy)以及集成全部候选模糊子模型的集成模型(En-fuzzy)的训练和测试样本的测量曲线如图3所示。

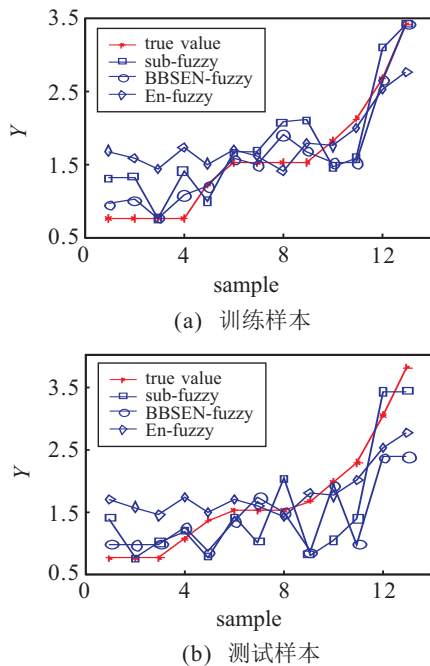


图3 模糊推理模型的训练和测试样本的测量曲线(MBVR)

由图3可以看出,本文所提出的选择性集成模糊推理模型的性能优于其他两种模型,这表明在建立模糊推理子模型的基础上,进行选择集成十分必要。

所构建的不同磨机负荷参数的选择性集成模糊推理模型选择了不同的多尺度频谱,例如:MBVR模型选择的是VIMF8、VIMF1和VIMF2,PD模型选择的是VIMF8和VIMF5,CVR模型选择的是AIMF4、VIMF3和AIMF1.其中CVR选择的结果与多尺度频

谱重要性度量的结果最为一致.从另一个角度看,多尺度频谱重要性度量与模糊推理模型间的关系也可以视为基于filter的特征选择方法,更适合的方法仍需要进一步研究。

### 3.2.4 基于EMD的选择性集成软测量结果比较

将本文方法与文献[12]和文献[13]基于EMD的选择性集成软测量方法进行比较,结果如表3所示。

表3 基于EMD的选择性集成软测量结果比较

方法	RMSREs				信号类型
	MBVR	PD	CVR	平均	
文献[12]	0.5454	0.3074	0.2527	0.3685	振动
文献[13]	0.3173	0.1876	0.1932	0.2327	振动、振声
本文	0.3045	0.2501	0.3369	0.2892	振动、振声

由表3可知,本文方法建立的MBVR模型具有最佳建模精度,这与本文所提方法是从模拟运行专家的推理认知行为的视角进行建模密不可分的.在实际工业现场中,MBVR也是运行专家基于振声信号最容易识别的磨机负荷参数。

本文采用自适应选择和提取的非线性潜在特征构建基于语言规则的模糊推理模型,从一定程度上可以模拟专家依据所听到的工业现场磨机声音的强弱判断磨机负荷参数状态的认知机制.研究表明,专家经验的积累需要达到一定数量时才能够具有推理认知能力,因此基于有限数据,该策略难以开展.这也许是本文方法的测量结果弱于文献[13]的一个原因.另外,专家在积累大量经验的过程中,既会运用存储有价值的经验,也会抛弃遗忘无用的经验.在某种程度上,这些经验所对应的就是数据建模时的训练样本.选择有价值的样本对模拟运行专家的认知模型进行补偿建模,是下一步值得研究的问题。

## 4 结论

本文提出了基于多尺度振动和振声频谱潜在特征自适应提取与选择的磨机负荷参数选择性集成模糊推理模型.本文的主要贡献为:1)采用EEMD分解算法模拟人耳带通滤波能力,实现了筒体振动信号的多尺度自适应分解;2)采用潜变量特征贡献率与磨机负荷参数互信息相结合的度量策略,自适应选择多尺度频谱特征参数,模拟人类听觉系统对有价值多尺度频谱特征的提取与选择能力;3)采用模糊推理集成模型,模拟运行专家的逐层认知、不确定性推理以及选择性信息融合的过程.通过实验磨机的筒体振动和振声信号验证了所提出方法的可行性。

## 参考文献(References)

- [1] Tang J, Chai T Y, Yu Y, et al. Modeling load parameters of ball mill in grinding process based on selective ensemble multisensor information[J]. IEEE Transactions on Automation Science and Engineering, 2013, 10(3): 726-740.
- [2] 汤健, 赵立杰, 岳恒, 等. 磨机负荷检测方法研究综述[J]. 控制工程, 2010, 17(5): 565-570.  
(Tang J, Zhao L J, Yue H, et al. Present status and future developments of detection method for mill load[J]. Control Engineering of China, 2010, 17(5): 565-570.)
- [3] Lei Y G, He Z J. Application of the EEMD method to rotor fault diagnosis of rotating machinery[J]. Mechanical Systems and Signal Processing, 2009, 23(4): 1327-1338.
- [4] Singh G K, Alkazzaz S A S. Isolation and identification of dry bearing faults in induction machine using wavelet transform[J]. Tribology International, 2009, 42(6): 849-861.
- [5] Cusido J, Romeral L, Ortega J A, et al. Fault detection in induction machines using power spectral density in wavelet decomposition[J]. IEEE Transactions on Industrial Electronics, 2008, 55(2): 633-643.
- [6] Riera-Guasp M, Antonino-Daviu J A, Pineda-Sanchez M, et al. A general approach for the transient detection of slip-dependent fault components based on the discrete wavelet transform[J]. IEEE Transactions on Industrial Electronics, 2008, 55(12): 4167-4180.
- [7] Kankar P K, Sharma S C, Harsha S P. Rolling element bearing fault diagnosis using auto correlation and continuous wavelet transform[J]. Journal of Vibration and Control, 2011, 17: 2081-2094.
- [8] Huang N E, Shen Z, Long S R. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings A, 1998, 454(1971): 903-995.
- [9] Jian Tang, Junfei Qiao, Zhuo Liu, et al. Mechanism characteristic analysis and soft measuring method review for ball mill load based on mechanical vibration and acoustic signals in the grinding process[J]. Minerals Engineering, 2018, 128: 294-311.
- [10] Rai V K, Mohanty A R. Bearing fault diagnosis using FFT of intrinsic mode functions in Hilbert-Huang transform[J]. Mechanical Systems and Signal Processing, 2007, 21(6): 2607-2615.
- [11] Tang J, Zhao L J, Yue H, et al. Vibration analysis based on empirical mode decomposition and partial least squares[J]. Procedia Engineering, 2011, 16: 646-652.
- [12] Zhao L J, Tang J, Zheng W R. Ensemble modeling of mill load based on empirical mode decomposition and partial least squares[J]. Journal of Theoretical and Applied Information Technology, 2012, 45: 179-191.
- [13] 汤健, 柴天佑, 丛秋梅, 等. 基于EMD和选择性集成学习算法的磨机负荷参数软测量[J]. 自动化学报, 2014, 40(9): 1853-1866.  
(Tang J, Chai T Y, Cong Q M, et al. Soft sensor approach for modeling mill load parameters based on EMD and selective ensemble learning algorithm[J]. Acta Automatica Sinica, 2014, 40(9): 1853-1866.)
- [14] Wu Z, Huang N E. Ensemble empirical mode decomposition: A noise-assisted data analysis method[J]. Advances in Adaptive Data Analysis, 2009, 1: 1-41.
- [15] Charanpal D, Gunn S R, John S T. Efficient sparse kernel feature extraction based on partial least squares[J]. IEEE Trans on Pattern Analysis & Machine Intelligence, 2008, 31(8): 1347-1361.
- [16] Wang L X, Mendel J M. Generating fuzzy rules by learning from examples[J]. IEEE Transactions on Systems, Man, and Cybernetics, 1992, 22(6): 1414-1427.
- [17] Yu W, Li X O. On-line fuzzy modeling via clustering and support vector machines[J]. Information Sciences, 2008, 178(2): 4264-4279.
- [18] 周平, 柴天佑. 磨矿过程磨机负荷的智能监测与控制[J]. 控制理论与应用, 2008, 25(6): 1095-1098.  
(Zhou P, Chai T Y. Intelligent monitoring and control of mill load for grinding processes[J]. Control Theory & Applications, 2008, 25(6): 1095-1098.)
- [19] 白锐, 柴天佑. 基于数据融合与案例推理的球磨机负荷优化控制[J]. 化工学报, 2009, 60(7): 1746-1752.  
(Bai R, Chai T Y. Optimization control of ball mill load in blending process with data fusion and case-based reasoning[J]. J of the Chemical Industry & Engineering Society of China, 2009, 60(7): 1746-1752.)
- [20] 刘卓, 汤健, 柴天佑, 等. 一种基于模糊推理的磨机负荷参数软测量方法[P]. 中国: CN105528636A. 2016-04-27.  
(Liu Z, Tang J, Chai T Y, et al. A soft sensing method for mill load parameters based on fuzzy inference[P]. China: CN105528636A. 2016-04-27.)
- [21] Zhou Z H, Wu J, Tang W. Ensembling neural networks: Many could be better than all[J]. Artificial Intelligence, 2002, 137(1): 239-263.
- [22] 汤健. 磨矿过程磨机负荷软测量方法的研究[D]. 沈阳: 东北大学信息科学与工程学院, 2012.  
(Tang J. Soft sensing of ball mill load for grinding process[D]. Shenyang: College of Information Science and Engineering, Northeastern University, 2012.)

## 作者简介

刘卓(1979—), 女, 讲师, 博士, 从事复杂工业过程建模的研究, E-mail: liuzhuo@mail.neu.edu.cn;

柴天佑(1947—), 男, 教授, 博士生导师, 中国工程院院士, 从事流程工业综合自动化理论、方法与技术等研究, E-mail: chaitianyou@mail.neu.edu.cn;

汤健(1974—), 男, 教授, 博士生导师, 从事复杂工业过程智能控制与建模等研究, E-mail: tjian001@126.com.

(责任编辑: 李君玲)