

基于多模态特征子集选择性集成建模的磨机负荷参数预测方法

刘卓¹ 汤健² 柴天佑¹ 余文³

摘要 如何融合球磨机系统研磨过程所产生的多模态机械信号构建磨机负荷参数预测 (Mill load parameter forecasting, MLPF) 模型是当前研究的热点. 针对上述问题, 本文提出一种基于多模态特征子集选择性集成 (Selective ensemble, SEN) 建模的 MLPF 方法. 首先, 对多模态机械信号进行时频域变换得到高维频谱数据; 接着, 采用相关系数法和互信息法对多模态频谱进行线性和非线性特征子集的自适应选择; 最后, 采用优化和加权算法对上述特征子集的候选子模型进行自适应地选择与合并, 得到基于 SEN 机制的 MLPF 模型. 采用磨矿过程实验球磨机的机械信号仿真验证了所提方法的有效性.

关键词 多模态机械信号, 特征子集, 选择性集成, 磨机负荷参数

引用格式 刘卓, 汤健, 柴天佑, 余文. 基于多模态特征子集选择性集成建模的磨机负荷参数预测方法. 自动化学报, 2021, 47(8): 1921–1931

DOI 10.16383/j.aas.c190735

Selective Ensemble Modeling Approach for Mill Load Parameter Forecasting Based on Multi-modal Feature Sub-sets

LIU Zhuo¹ TANG Jian² CHAI Tian-You¹ YU Wen³

Abstract How to fuse the multi-modal mechanical signals of the ball mill grinding system to construct mill load parameter forecasting (MLPF) model is a hot issue in current research. Aiming at the above problem, a new selective ensemble (SEN) modeling approach for MLPF based on multi-modal feature sub-sets is proposed. Firstly, time-frequency domain transformation is performed on the multi-modal mechanical signals to obtain high-dimensional spectral data; Then, linear and non-linear feature subsets are adaptively selected from multi-modal frequency spectrum by using feature selection approaches based on correlation coefficient and mutual information method. Finally, linear and non-linear candidate sub-models based on different multi-modal feature sub-sets are constructed, which are adaptively selected and combined by using optimal selection and weighting algorithm jointly. Thus, the final SEN model for MLPF is obtained. Simulation results based on mechanical signals of a laboratory scale ball mill showed the effectiveness of the proposed method.

Key words Multi-modal mechanical signal, feature sub-set, selective ensemble modeling, mill load parameter

Citation Liu Zhuo, Tang Jian, Chai Tian-You, Yu Wen. Selective ensemble modeling approach for mill load parameter forecasting based on multi-modal feature sub-sets. *Acta Automatica Sinica*, 2021, 47(8): 1921–1931

收稿日期 2019-10-23 录用日期 2020-02-07

Manuscript received October 23, 2019; accepted February 7, 2020

国家自然科学基金 (61703089, 61803191, 61673097), 中央高校基本科研业务费专项资金项目 (N17080400), 矿冶过程自动控制技术国家重点实验室, 矿冶过程自动控制技术北京市重点实验室 (BGRIMM-KZSKL-2020-02) 资助

Supported by National Natural Science Foundation of China (61703089, 61803191, 61673097), the Fundamental Research Funds for the Central Universities (N17080400), National & Beijing Key Laboratory of Process Automation in Mining & Metallurgy (BGRIMM-KZSKL-2020-02)

本文责任编辑 莫红

Recommended by Associate Editor MO Hong

1. 东北大学流程工业综合自动化国家重点实验室 沈阳 110819 中国 2. 北京工业大学信息学部 北京 100124 中国 3. 墨西哥国立理工大学高级研究中心 (CINVESTAV-IPN) 墨西哥 07360 墨西哥

1. State Key Laboratory of Synthetical Automation for Process Industries, North-eastern University, Shenyang 110819, China 2. Faculty of Information Technology, Beijing University of Technology, Beijing 100124, China 3. Departamento de Control Automatico, Centro de Investigacion de Estudios Avanzados, National Polytechnic Institute Mexico, México D. F. 07360, Mexico

磨矿过程难以检测的磨机负荷参数 (Mill load parameter, MLP), 即料球比 (Material to ball volume ratio, MBVR)、磨矿浓度 (Pulp density, PD) 和充填率 (Ball charge volume ratio, CVR), 与磨矿过程的产品质量和生产效率密切相关, 对其进行实时检测是实现选矿过程运行优化控制的关键因素之一^[1-2]. 数据驱动的软测量建模技术广泛用于类似难测参数的推理估计^[3]. 旋转运行的磨机在筒体、轴承、研磨区域等不同位置所产生的机械振动/振声信号, 在产生机理、灵敏度和蕴含信息等方面存在差异性、冗余性与互补性^[4-5]. 文献 [6] 指出事物被体验或表达存在多种特定方式 (模态), 可融合多模态的有价值信息实现分类或回归. 针对球磨机系统, 蕴含着差异化 MLP 信息的多模态机械振动/振声信号频谱特征常用于构建 MLPF 模型^[7-9].

为构建具有可解释性和较强泛化能力的 MLPF 模型, 进行多模态频谱特征的有效选择是较为有效的策略. 特征选择算法能够有效去除“无关特征”与“冗余特征”, 并确保重要特征不丢失^[10]. 针对机械振动频谱进行特征子集的选择更具有价值^[11]. 此外, 不同 MLP 与高维特征间的映射关系也呈现出差异性.

基于单个输入特征与 MLP 等难测参数间的相关系数能够选择线性相关特征, 如文献 [12] 结合多目标优化算法和相关系数进行微阵列数据的特征选择, 文献 [13] 提出基于相关系数的多目标半监督特征选择方法, 文献 [14] 提出基于熵的相关系数的特征聚类方法对特征子集进行快速聚类. 针对基于相关系数的线性方法难以描述复杂非线性映射关系的缺点, 互信息法可有效选择与难测参数相关的非线性特征^[15-16], 如文献 [17-18] 提出了基于个体最佳互信息和条件互信息的特征选择方法. 针对高维频谱数据, 如何自适应确定特征选择阈值并进行有效的线性和非线性特征子集的选择是待解决的开放问题.

在选择包含不同数量特征的线性和非线性频谱特征子集后, 还需解决 MLPF 的构建问题. 通常, 上述线性和非线性机械频谱特征子集间存在冗余性和互补性. 基于这些特征子集所构建的线性或非线性模型针对不同 MLP 参数的预测性能也存在差异性. 集成建模通过组合多个异质或同质子模型的输出提高预测模型的稳定性和鲁棒性, 其难点问题是提高子模型间的多样性. 文献 [19] 指出子模型多样性的构造策略包括样本空间重采样、特征空间特征子集划分或特征变换等, 其中基于特征空间的构造策略能够获得最佳的预测性能.

基于较高频率分辨率获得的单/多尺度频谱间具有较强的共线性. 潜结构映射或偏最小二乘 (Partial least squares, PLS) 算法能够提取低维潜在变量 (Latent variable, LV) 构建回归模型, 适合对高维频谱数据建模^[20-21]. 为提高 MLPF 模型泛化性能, 文献 [22] 提出基于“操作输入特征”与“采样训练样本”的双重维度集成构造策略, 用以构建 SEN MLPF 模型; 该方法构建的模型能够有效融合多源有价值信息, 与运行专家感知 MLP 的机制相类似, 但所构建的 MLPF 模型结构较为复杂. 此外, 上述方法属于同质子模型集成, 并且未对频谱特征进行线性或非线性子集的选择. 面对小样本, 基于单尺度频谱构建的 MLPF 模型的泛化性能较好, 但在模型可解释性和洞悉研磨过程机理等方面存在欠缺. 随机神经网络 (Random weight neural network, RWNN) 是隐含层输入权重随机产生、输出权重采用 Moore-Penrose 广义逆方法计算的单隐含

层神经网络^[23-24], 具有较快的学习速度. 为克服工况漂移带来的泛化性能下降问题, 文献 [25-27] 构建了基于更新样本和迁移学习的 MLPF 模型. 为选择更有价值的多模态机械信号, 文献 [28] 提出了面向 MLPF 的信号分析评估与优化组合算法, 但其并未进行多模态特征子集的选择.

在已有研究中, 关于多模态特征选择与融合的研究多偏向基于图像的应用领域, 如文献 [29] 利用多核学习方法融合对图像所提取的颜色、纹理、轮廓、深度等多模态特征进行分类检测; 文献 [30] 提出融合语音信号和脑电信号的多模态情感识别; 文献 [31] 综述多模态功能神经影像的多元机器学习融合方法; 文献 [32] 综述了深度多模态学习, 指出采用正则化方法对多模态融合结构进行学习和优化是研究热点; 文献 [33] 提出采用多种深度神经网络的多模态融合策略手势识别. 上述研究的多模态主要是从数据来源的视角进行, 存在的问题是深度融合方法难以对所选择多模态特征进行合理的物理解释.

因此, 基于多模态机械频谱的 MLPF 模型构建, 需要解决以下 2 个问题: 1) 如何进行线性特征和非线性特征子集的选择; 2) 如何基于多模态特征子集构建差异性的集成子模型并进行有效选择与合并以构建 SEN 模型. 综上, 本文提出了一种基于多模态特征子集 SEN 建模的 MLPF 方法. 首先, 对多模态机械信号进行时频域变换得到高维频谱数据; 然后, 采用相关系数法和互信息法对多模态频谱变量进行线性和非线性特征子集的自适应选择; 接着, 构建基于多模态特征的候选子模型后进行自适应选择与合并, 进而获得基于 SEN 的 MLPF 模型. 采用磨矿过程实验球磨机的多模态机械振动信号仿真验证了所提方法的有效性.

1 磨机机械信号的多模态特性分析

球磨机是依靠钢球和矿石间的冲击和研磨进行破碎的重型旋转设备. 磨机系统不同位置机械信号的产生机理如图 1 所示^[28].

图中, x_{VS}^t 表示筒体振动信号, x_{V1}^t 和 x_{V2}^t 表示前后轴承座机械振动信号, x_{AS}^t 表示筒体表面振声信号, x_{A1}^t 表示磨机研磨区域下方振声信号.

如图 1 所示, 分层排列的钢球随球磨机旋转以不同的冲击力和周期被抛落或滑落, 这些冲击力相互叠加导致筒体振动; 同时, 磨机自身质量的不平衡和安装偏置也引起筒体振动, 这些叠加后的冲击力导致筒体振动 x_{VS}^t . 显然, 磨机旋转整周期的不同阶段所蕴含的 MLP 信息具有差异性. 筒体振动经机械传动设备的多级传递会滤掉高频部分, 其残余振动导致磨机前后轴承座在水平和垂直方向的振

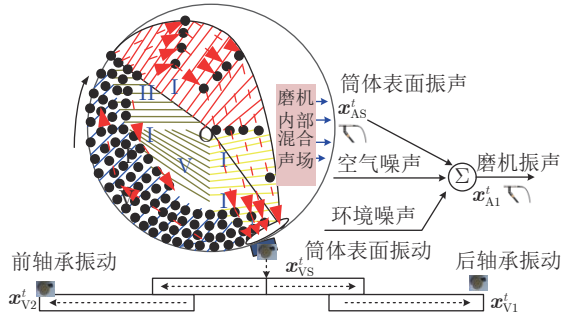


图 1 磨机系统不同位置机械信号的产生机理示意图
Fig.1 Generation mechanism of mechanical signals in different position of mill system

动,再耦合其他来源振动后导致轴承座振动 x_{V1}^t 和 x_{V2}^t . 球磨机内部噪声经连续反射后形成混合声场,经磨机筒体传出产生空气噪声,筒体振动的声发射机理产生结构噪声,此两种噪声是筒体近表面振声 x_{AS}^t 的主要组成部分;此外,磨机研磨区域下方的振声 x_{A1}^t 还包含来自其他磨机和邻近设备的背景噪声.

因此,球磨机系统不同位置测量的多模态机械信号所蕴含的 MLP 信息具有冗余性和互补性.理论上,不同区域的频谱具有其特定的物理含义.因此,有必要对多模态机械频谱特征进行选择融合.

2 建模策略

本文提出了由时频域变换、多模态线性/非线性特征子集选择、多模态 SEN 模型构建共 3 个模块组成的建模策略,如图 2 所示.

图 2 中, J 表示多模态机械信号的测量数量, X^j 表示基于设计方案进行 N 次实验所采集的长度为 M 的第 j 个模态的机械信号, Z^j 表示将 X^j 采用 FFT (Fast Fourier transform) 技术变换至频域获得的机械频谱, Z_{lin}^j 和 Z_{nonlin}^j 表示基于 Z^j 所提取的线性和非线性特征子集, \hat{y}_{linPLS}^j 和 $\hat{y}_{linRWNN}^j$ 表示基于线性特征子集 Z_{lin}^j 构建的线性 PLS 和非线性 RWNN 子模型的预测输出, $\hat{y}_{nonlinPLS}^j$ 和 $\hat{y}_{nonlinRWNN}^j$ 表示基于非线性子集 Z_{nonlin}^j 构建的线性 PLS 和非线性 RWNN 子模型的预测输出, y 和 \hat{y} 表示 MLP 及其预测输出, J_{sel} 和 k_{feasel} 表示 MLPF 软测量模型的集成尺寸和特征选择系数.

3 建模算法

3.1 时频域变换

以基于设计方案进行 N 次实验所采集的长度为 M 的第 j 个模态的机械信号 X^j 为例,可用如下

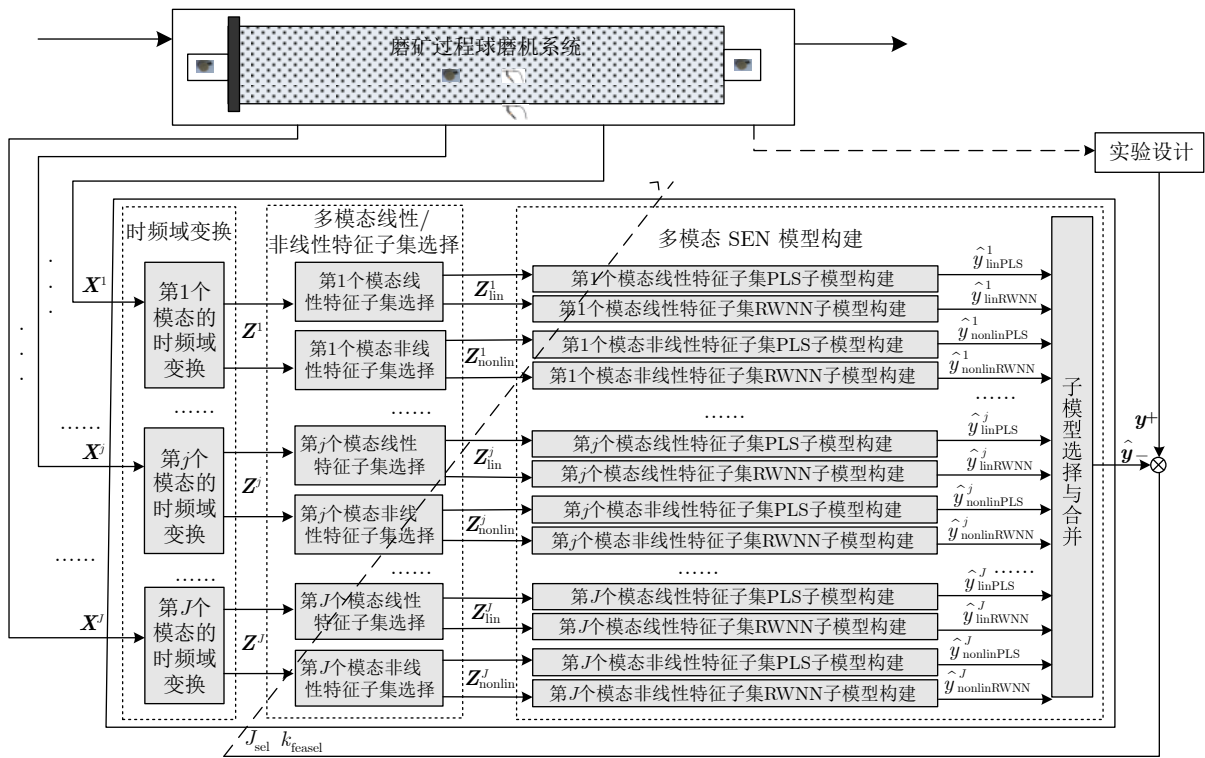


图 2 建模策略

Fig.2 The proposed modeling strategy

矩阵表示,

$$\mathbf{X}^j = \begin{bmatrix} \mathbf{x}_1^j \\ \dots \\ \mathbf{x}_n^j \\ \dots \\ \mathbf{x}_N^j \end{bmatrix} = \begin{bmatrix} x_{11}^j & \dots & x_{1m}^j & \dots & x_{1M}^j \\ \dots & \dots & \dots & \dots & \dots \\ x_{n1}^j & \dots & x_{nm}^j & \dots & x_{nM}^j \\ \dots & \dots & \dots & \dots & \dots \\ x_{N1}^j & \dots & x_{Nm}^j & \dots & x_{NM}^j \end{bmatrix} \quad (1)$$

将上式中的第 n 次实验的时域信号 \mathbf{x}_n^j 变换至频域获得机械频谱 z_n^j , 可采用如下过程表示,

$$\mathbf{x}_n^j = [x_{n1}^j, \dots, x_{nm}^j, \dots, x_{nM}^j] \xrightarrow{\text{FFT}} z_n^j \quad (2)$$

进一步, 将全部 N 次实验 (建模的 N 个样本) 的第 j 个模态的机械信号均变换至频域, 可得到 \mathbf{Z}^j , 可改写为如下式所示,

$$\mathbf{Z}^j = \begin{bmatrix} \mathbf{z}_1^j \\ \dots \\ \mathbf{z}_n^j \\ \dots \\ \mathbf{z}_N^j \end{bmatrix} = \begin{bmatrix} z_{11}^j & \dots & z_{1p}^j & \dots & z_{1P}^j \\ \dots & \dots & \dots & \dots & \dots \\ z_{n1}^j & \dots & z_{np}^j & \dots & z_{nP}^j \\ \dots & \dots & \dots & \dots & \dots \\ z_{N1}^j & \dots & z_{Np}^j & \dots & z_{NP}^j \end{bmatrix} = \begin{bmatrix} z_1^j & \dots & z_p^j & \dots & z_P^j \end{bmatrix} \quad (3)$$

式中, N 和 P 分别代表建模样本的数量和维数, 即 P 为频谱特征的数量, z_p^j 表示第 p 个输入特征. 相应的, 磨机负荷难测参数的真值表示为 $\mathbf{y} = \{y_n\}_{n=1}^N$.

进一步, 全部 J 个模态的机械信号的频谱可表示为 $\{\mathbf{Z}_j\}_{j=1}^J$.

3.2 多模态线性/非线性特征子集选择

以第 j 个模态为例, 首先计算第 p 个频谱变量 z_p^j 的相关系数的绝对值, 如下所示,

$$\xi_p^j = \left| \frac{\sum_{n=1}^N [(z_{np}^j - \bar{z}_p^j)(y_n - \bar{y})]}{\sqrt{\sum_{n=1}^N (z_{np}^j - \bar{z}_p^j)^2} \sqrt{\sum_{n=1}^N (y_n - \bar{y})^2}} \right| \quad (4)$$

其中, \bar{z}_p^j 和 \bar{y} 分别表示第 p 个频谱输入特征和 MLP 的全部 N 个建模样本的平均值, $|\cdot|$ 表示取绝对值. 为表述方便, 后文称 ξ_p^j 为第 j 个模态第 p 个频谱特征的相关系数值.

重复上述过程, 获得全部输入特征的相关系数并记为 $\{\xi_p^j\}_{p=1}^P$.

接着, 计算第 j 个模态中最大和最小线性相关系数与均值的比值 k_{linMin}^j 和 k_{linMax}^j , 如下所示,

$$k_{\text{linMin}}^j = \min(\{\xi_p^j\}_{p=1}^P) / \left(\frac{1}{P} \sum_{p=1}^P \xi_p^j \right) \quad (5)$$

$$k_{\text{linMax}}^j = \max(\{\xi_p^j\}_{p=1}^P) / \left(\frac{1}{P} \sum_{p=1}^P \xi_p^j \right) \quad (6)$$

对全部模态执行上述过程后, 采用如下公式获得线性特征选择系数的上限和下限,

$$k_{\text{lin}}^{\text{Up}} = \min(\{k_{\text{linMax}}^j\}_{j=1}^J) \quad (7)$$

$$k_{\text{lin}}^{\text{Down}} = \max(\{k_{\text{linMin}}^j\}_{j=1}^J) \quad (8)$$

仍以第 j 个模态为例, 首先计算第 p 个频谱变量 z_p^j 的互信息值, 如下所示,

$$\zeta_p^j = \sum_{n=1}^N \sum_{n=1}^N p_{\text{rob}}(z_{np}^j, \mathbf{y}_n) \log \left(\frac{p_{\text{rob}}(z_{np}^j, \mathbf{y}_n)}{p_{\text{rob}}(z_{np}^j) p_{\text{rob}}(\mathbf{y}_n)} \right) \quad (9)$$

其中, $p_{\text{rob}}(z_{np}^j, \mathbf{y}_n)$ 表示联合概率密度, $p_{\text{rob}}(z_{np}^j)$ 和 $p_{\text{rob}}(\mathbf{y}_n)$ 表示边际概率密度.

重复上述过程, 获得频谱特征的互信息值并记为 $\{\zeta_p^j\}_{p=1}^P$.

接着, 计算第 j 个模态中最大和最小互信息值与均值的比值, 如下所示,

$$k_{\text{nonlinMin}}^j = \min(\{\zeta_p^j\}_{p=1}^P) / \left(\frac{1}{P} \sum_{p=1}^P \zeta_p^j \right) \quad (10)$$

$$k_{\text{nonlinMax}}^j = \max(\{\zeta_p^j\}_{p=1}^P) / \left(\frac{1}{P} \sum_{p=1}^P \zeta_p^j \right) \quad (11)$$

对全部模态执行上述过程后, 采用如下公式获得非线性特征选择系数的上限和下限,

$$k_{\text{nonlin}}^{\text{Up}} = \min(\{k_{\text{nonlinMax}}^j\}_{j=1}^J) \quad (12)$$

$$k_{\text{nonlin}}^{\text{Down}} = \max(\{k_{\text{nonlinMin}}^j\}_{j=1}^J) \quad (13)$$

进一步, 采用如下公式获得频谱特征选择系数的上限和下限,

$$k_{\text{feasel}}^{\text{Up}} = \min(k_{\text{nonlin}}^{\text{Up}}, k_{\text{lin}}^{\text{Up}}) \quad (14)$$

$$k_{\text{feasel}}^{\text{Down}} = \max(k_{\text{nonlin}}^{\text{Down}}, k_{\text{lin}}^{\text{Down}}) \quad (15)$$

本文中, 对全部模态采用相同的特征选择系数 k_{feasel} .

按如下公式结合预测性能自适应确定 J_{feasel} 个特征选择系数的取值,

$$k_{\text{feasel}} = k_{\text{feasel}}^{\text{Down}} : k_{\text{feasel}}^{\text{step}} : k_{\text{feasel}}^{\text{Up}} \quad (16)$$

其中, k_{feasel} 取为 1 时, 表示阈值为均值; $k_{\text{feasel}}^{\text{step}}$ 表示用于计算 J_{feasel} 个特征选择系数的步长, 采用如下

公式获得,

$$k_{\text{feasel}}^{\text{step}} = \frac{k_{\text{feasel}}^{\text{Up}} - k_{\text{feasel}}^{\text{Down}}}{J_{\text{feasel}}} \quad (17)$$

不同模态的线性特征和非线性特征的选择阈值 θ_{feasel}^j 采用如下公式获得,

$$\theta_{\text{linfeasel}}^j = k_{\text{feasel}} \cdot \left(\frac{1}{P} \sum_{p=1}^P \xi_p^j \right) \quad (18)$$

$$\theta_{\text{nonlinfeasel}}^j = k_{\text{feasel}} \cdot \left(\frac{1}{P} \sum_{p=1}^P \zeta_p^j \right) \quad (19)$$

以第 j 个模态的第 p 个输入特征为例, 线性特征按如下规则进行选择,

$$\alpha_p^j = \begin{cases} 1, & \xi_p^j \geq \theta_{\text{linfeasel}}^j \\ 0, & \xi_p^j < \theta_{\text{linfeasel}}^j \end{cases} \quad (20)$$

选择其中 $\alpha_p^j = 1$ 的变量作为基于阈值 $\theta_{\text{linfeasel}}^j$ 选择的线性特征, 对第 j 个模态的全部原始特征执行上述过程并将线性特征子集记为 $\mathbf{Z}_{\text{linfea}}^j$, 进一步表示为,

$$\mathbf{Z}_{\text{linfea}}^j = [z^1, \dots, z^{P_{\text{linfea}}^j}, \dots, z^{P_{\text{linfea}}^j}] = [(z_{\text{linfea}}^j)_1, \dots, (z_{\text{linfea}}^j)_n, \dots, (z_{\text{linfea}}^j)_N]^T \quad (21)$$

其中, $z^{P_{\text{linfea}}^j}$ 表示 $\mathbf{Z}_{\text{linfea}}^j$ 中的第 P_{linfea}^j 个特征, $P_{\text{linfea}}^j = 1, \dots, P_{\text{linfea}}^j$, P_{linfea}^j 表示 $\mathbf{Z}_{\text{linfea}}^j$ 特征的数量; $(z_{\text{linfea}}^j)_n$ 表示 $\mathbf{Z}_{\text{linfea}}^j$ 的第 n 个样本; $(z_{\text{linfea}}^j)_N$ 表示 $\mathbf{Z}_{\text{linfea}}^j$ 的第 N 个样本.

进一步, 将全部 J 个模态的线性特征子集标记为 $\{\mathbf{X}_{\text{linfea}}^j\}_{j=1}^J$.

对第 j 个模态执行类似上述线性特征子集的选择过程, 并将所选择的非线性特征子集记为 $\mathbf{Z}_{\text{nonlinfea}}^j$, 进一步表示为,

$$\mathbf{Z}_{\text{nonlinfea}}^j = [z^1, \dots, z^{P_{\text{nonlinfea}}^j}, \dots, z^{P_{\text{nonlinfea}}^j}] = [(z_{\text{nonlinfea}}^j)_1, \dots, (z_{\text{nonlinfea}}^j)_n, \dots, (z_{\text{nonlinfea}}^j)_N]^T \quad (22)$$

其中, $z^{P_{\text{nonlinfea}}^j}$ 表示 $\mathbf{Z}_{\text{nonlinfea}}^j$ 中的第 $P_{\text{nonlinfea}}^j$ 个特征, $P_{\text{nonlinfea}}^j = 1, \dots, P_{\text{nonlinfea}}^j$, $P_{\text{nonlinfea}}^j$ 表示 $\mathbf{Z}_{\text{nonlinfea}}^j$ 特征的数量; $(z_{\text{nonlinfea}}^j)_n$ 表示 $\mathbf{Z}_{\text{nonlinfea}}^j$ 的第 n 个样本, $(z_{\text{nonlinfea}}^j)_N$ 表示 $\mathbf{Z}_{\text{nonlinfea}}^j$ 的第 N 个样本.

进一步, 将全部 J 个模态的非线性特征子集标记为 $\{\mathbf{Z}_{\text{nonlinfea}}^j\}_{j=1}^J$.

3.3 多模态 SEN 模型构建

偏最小二乘 (PLS) 算法的目标是通过最大化输入输出数据间的协方差, 将原始输入特征空间的

信息投影到由少数潜在变量 (LV) 组成新空间^[11]. 以第 j 个线性特征子集 $\mathbf{Z}_{\text{linfea}}^j$ 构建线性 PLS 子模型 $f_{\text{linPLS}}^j(\cdot)$ 为例, 其构建过程可表示为,

$$\left\{ \mathbf{Z}_{\text{linfea}}^j, \mathbf{y} \right\} \xrightarrow{f_{\text{linPLS}}^j(\cdot)} \left\{ \mathbf{T}_{\text{linPLS}}^j, \mathbf{U}_{\text{linPLS}}^j, \mathbf{W}_{\text{linPLS}}^j, \mathbf{P}_{\text{linPLS}}^j, \mathbf{Q}_{\text{linPLS}}^j, \mathbf{B}_{\text{linPLS}}^j \right\} \quad (23)$$

其中, $\mathbf{T}_{\text{linPLS}}^j = [t_1, \dots, t_{h_{\text{linPLS}}^j}, \dots, t_{H_{\text{linPLS}}^j}]$ 和 $\mathbf{U}_{\text{linPLS}}^j = [\mathbf{u}_1, \dots, \mathbf{u}_{h_{\text{linPLS}}^j}, \dots, \mathbf{u}_{H_{\text{linPLS}}^j}]$ 分别表示输入输出数据的潜在变量 (得分) 矩阵; $\mathbf{W}_{\text{linPLS}}^j = [\mathbf{w}_1, \dots, \mathbf{w}_{h_{\text{linPLS}}^j}, \dots, \mathbf{w}_{H_{\text{linPLS}}^j}]$ 表示权重矩阵, $\mathbf{P}_{\text{linPLS}}^j = [\mathbf{p}_1, \dots, \mathbf{p}_{h_{\text{linPLS}}^j}, \dots, \mathbf{p}_{H_{\text{linPLS}}^j}]$ 和 $\mathbf{Q}_{\text{linPLS}}^j = [\mathbf{q}_1, \dots, \mathbf{q}_{h_{\text{linPLS}}^j}, \dots, \mathbf{q}_{H_{\text{linPLS}}^j}]$ 分别表示输入和输出数据的载荷矩阵, $\mathbf{B}_{\text{linPLS}}^j = \text{diag} \{ \mathbf{b}_1, \dots, \mathbf{b}_{h_{\text{linPLS}}^j}, \dots, \mathbf{b}_{H_{\text{linPLS}}^j} \}$ 表示回归系数矩阵, H_{linPLS}^j 表示基于验证数据集获得的 LV 数量.

线性 PLS 子模型 $f_{\text{linPLS}}^j(\cdot)$ 的预测输出可表示为

$$\hat{\mathbf{y}}_{\text{linPLS}}^j = \mathbf{Z}_{\text{linfea}}^j (\mathbf{Z}_{\text{linfea}}^j)^T \mathbf{U}_{\text{linPLS}}^j \cdot \left((\mathbf{T}_{\text{linPLS}}^j)^T \mathbf{Z}_{\text{linfea}}^j (\mathbf{Z}_{\text{linfea}}^j)^T \mathbf{U}_{\text{linPLS}}^j \right)^{-1} (\mathbf{T}_{\text{linPLS}}^j)^T \quad (24)$$

对全部 J 个模态的线性特征子集执行上述过程, 由全部线性特征构建的线性特征线性子模型子集及其预测输出分别为 $\{f_{\text{linPLS}}^j(\cdot)\}_{j=1}^J$ 和 $\{\hat{\mathbf{y}}_{\text{linPLS}}^j\}_{j=1}^J$.

类似地, 以全部非线性特征子集 $\{\mathbf{Z}_{\text{nonlinfea}}^j\}_{j=1}^J$ 采用 PLS 构建的非线性特征线性子模型子集及其预测输出分别为 $\{f_{\text{nonlinPLS}}^j(\cdot)\}_{j=1}^J$ 和 $\{\hat{\mathbf{y}}_{\text{nonlinPLS}}^j\}_{j=1}^J$.

以第 j 个线性特征子集 $\mathbf{Z}_{\text{linfea}}^j$ 构建非线性 RWNN 子模型 $f_{\text{linRWNN}}^j(\cdot)$ 为例, 基于随机产生的输入权重 $\mathbf{w}_{\text{linRWNN}}^j$ 和偏置 b_{linRWNN}^j , 以及激活函数 $g(\cdot)$ 获得隐含层神经元的输出矩阵 $\mathbf{H}_{\text{linRWNN}}^j$ 如下所示,

$$\mathbf{H}_{\text{linRWNN}}^j = \begin{bmatrix} g \left(\left(\mathbf{w}_{\text{linRWNN}}^j \right)_1 \cdot \left(z_{\text{linfea}}^j \right)_1 + \left(b_{\text{linRWNN}}^j \right)_1 \right), \\ \dots, g \left(\left(\mathbf{w}_{\text{linRWNN}}^j \right)_L \cdot \left(z_{\text{linfea}}^j \right)_1 + \left(b_{\text{linRWNN}}^j \right)_L \right), \\ \dots, g \left(\left(\mathbf{w}_{\text{linRWNN}}^j \right)_1 \cdot \left(z_{\text{linfea}}^j \right)_N + \left(b_{\text{linRWNN}}^j \right)_1 \right), \\ \dots, g \left(\left(\mathbf{w}_{\text{linRWNN}}^j \right)_L \cdot \left(z_{\text{linfea}}^j \right)_N + \left(b_{\text{linRWNN}}^j \right)_L \right) \end{bmatrix} \quad (25)$$

其中, L 表示基于验证数据集的预测误差获得的隐含层节点数.

进一步, 通过 $\mathbf{H}_{\text{linRWNN}}^j$ 的 Moore-Penrose 广义逆矩阵 $(\mathbf{H}_{\text{linRWNN}}^j)^\dagger$ 得到隐含层的输出权值,

$$\hat{\beta}_{\text{linRWNN}}^j = (\mathbf{H}_{\text{linRWNN}}^j)^\dagger \mathbf{y} \quad (26)$$

基于线性特征子集 $\mathbf{Z}_{\text{linfea}}^j$ 的非线性 RWNN 子模型 $f_{\text{nonlinRWNN}}^j(\cdot)$ 的预测输出可表示为,

$$\hat{\mathbf{y}}_{\text{nonlinRWNN}}^j = \left((\mathbf{H}_{\text{linRWNN}}^j)^\dagger \right)^\top \cdot \hat{\beta}_{\text{linRWNN}}^j \quad (27)$$

对全部 J 个模态的线性特征子集执行上述过程, 由全部线性特征子集构建的非线性特征线性子模型子集及其预测输出分别为 $\{f_{\text{linRWNN}}^j(\cdot)\}_{j=1}^J$ 和 $\{\hat{\mathbf{y}}_{\text{linRWNN}}^j\}_{j=1}^J$.

类似地, 基于非线性特征子集 $\{\mathbf{Z}_{\text{nonlinfea}}^j\}_{j=1}^J$ 采用 RWNN 构建的非线性特征非线性子模型子集及其预测输出分别为 $\{f_{\text{nonlinRWNN}}^j(\cdot)\}_{j=1}^J$ 和 $\{\hat{\mathbf{y}}_{\text{nonlinRWNN}}^j\}_{j=1}^J$.

将上述全部 J 个模态的 4 类子模型的预测输出按如下方式进行合并,

$$\{\hat{\mathbf{y}}_{\text{can}}^{j_{\text{can}}}\}_{j_{\text{can}}=1}^{4J} = [\{\hat{\mathbf{y}}_{\text{linPLS}}^j\}_{j=1}^J, \{\hat{\mathbf{y}}_{\text{nonlinPLS}}^j\}_{j=1}^J, \{\hat{\mathbf{y}}_{\text{linRWNN}}^j\}_{j=1}^J, \{\hat{\mathbf{y}}_{\text{nonlinRWNN}}^j\}_{j=1}^J] \quad (28)$$

其中, $4J$ 为全部 4 类子模型的数量, 也是候选子模型的数量; $\hat{\mathbf{y}}_{\text{can}}^{j_{\text{can}}}$ 表示第 j_{can} 个候选子模型的输出, $j_{\text{can}}=1, \dots, 4J$.

此处, 需要采用优化算法从 $4J$ 个候选子模型中选择 J_{sel} 个集成子模型 (即 SEN 模型的集成尺寸) 并对 J_{sel} 个集成子模型的预测输出进行组合, 得到最终基于 SEN 的 MLPF 预测模型的输出, 即存在如下关系,

$$\begin{cases} \hat{\mathbf{y}} = f_{\text{SEN}} \left(\{\hat{\mathbf{y}}^{j_{\text{sel}}}\}_{j_{\text{sel}}=1}^{J_{\text{sel}}} \right) \\ \{\hat{\mathbf{y}}^{j_{\text{sel}}}\}_{j_{\text{sel}}=1}^{J_{\text{sel}}} \in \{\hat{\mathbf{y}}^j\}_{j=1}^{4J} \end{cases} \quad (29)$$

其中, $f_{\text{SEN}}(\cdot)$ 表示对 J_{sel} 个集成子模型的预测输出进行合并的算法.

针对上述问题, 此处采用的策略是: 首先选定用于合并集成子模型预测输出的算法, 然后以最小化 SEN 模型的均方根相对误差 (Root mean square relative error, RMSRE) 为准则, 采用优化算法寻优 $f_{\text{SEN}}(\cdot)$ J_{sel} 个集成子模型并对其输出进行合并, 得到集成尺寸为 J_{sel} 的 SEN 模型.

用于对 J_{sel} 个集成子模型的预测输出进行合并的算法 $f_{\text{SEN}}(\cdot)$ 主要包括计算集成子模型的加权系数法和采用线性、非线性回归建模方法构建集成子模型输出与 SEN 模型输出间的映射关系. 其中, 加权系数法包括简单平均方法、自适应加权融合方法和误差信息熵加权方法. 本文采用自适应加权融合算法:

采用如下公式获得 SEN 模型的输出,

$$\hat{\mathbf{y}} = f_{\text{SEN}} \left(\{\hat{\mathbf{y}}^{j_{\text{sel}}}\}_{j_{\text{sel}}=1}^{J_{\text{sel}}} \right) = \sum_{j_{\text{sel}}=1}^{J_{\text{sel}}} w^{j_{\text{sel}}} \hat{\mathbf{y}}^{j_{\text{sel}}} \quad (30)$$

其中, $w^{j_{\text{sel}}}$ 表示第 j_{sel} 个集成子模型的加权系数, 满

足条件 $\sum_{j_{\text{sel}}=1}^{J_{\text{sel}}} w^{j_{\text{sel}}} = 1$.

$$w^{j_{\text{sel}}} = \frac{1}{(\sigma^{j_{\text{sel}}})^2 \sum_{j_{\text{sel}}=1}^{J_{\text{sel}}} \frac{1}{(\sigma^{j_{\text{sel}}})^2}} \quad (31)$$

其中, $\sigma^{j_{\text{sel}}}$ 是第 j_{sel} 个集成子模型的预测输出 $\hat{\mathbf{y}}^{j_{\text{sel}}}$ 的标准差.

4 实验验证

4.1 实验数据描述

以基于实验球磨机的高维筒体振动频谱对 MLPF 进行建模以验证本文所提方法. 本实验在直径为 602 mm 和长度为 715 mm 的小型实验磨机上进行, 其中磨机筒体的旋转速度为 42 r/min. 全部 8 个模态机械信号的采样频率均为 51 200 Hz, 传感器安装位置和类型: 1) 固定在磨机筒体表面的 2 个加速度传感器; 2) 与磨机筒体表面相距 2 mm 的 2 个声传感器; 3) 位于磨机轴承座左侧测量垂直振动、右侧测量垂直和水平振动的 3 个加速度传感器; 4) 位于磨机研磨区域下方 10 mm 的 1 个声传感器. 这些模态依次被标记为 Ch1 ~ Ch8, 如图 3 所示^[28].




图 3 实验球磨机传感器布置示意图

Fig. 3 Layout of sensors for experimental ball mill

共进行了 5 种工况下的 527 次实验: 第 1 次 ($B = 292$ kg, $W = 35$ kg, $M = 25.5 \sim 174$ kg); 第 2 次 ($B = 340.69$ kg, $W = 40$ kg, $M = 29.7 \sim 170.1$); 第 3 次 ($B = 389.36$ kg, $W = 40$ kg, $M = 34.2 \sim 157.5$ kg); 第 4 次 ($B = 438.03$ kg, $W = 35$ kg, $M = 23.4 \sim 151.2$ kg); 第 5 次 ($B = 486.7$ kg, $W = 40$ kg, $M = 15.3 \sim 144.9$ kg), 其中, B 、 M 、 W 分别代表钢球、物料和水负荷. 上述实验均是在固定钢球和水负荷, 逐渐增加矿石负荷的情况进行的. 将全部样本中的 4/5 用做训练和验证数据集, 其余的用于模型测试.

4.2 实验结果

4.2.1 时频域转换结果

首先, 对时域信号进行滤波处理; 然后, 采用 FFT 技术将磨机运行中稳定旋转周期的数据转换至频域, 得到每个模态的多个旋转周期的单尺度频谱; 最后, 将这些稳定旋转周期的谱数据进行平均, 获得最终维数为 12 800 的建模频谱. 部分实验的频谱曲线详见文献 [28].

4.2.2 特征子集选择结果

基于 317 个训练数据, 计算全部 8 个模态的频谱变量分别与三个磨机负荷参数 (MBVR、CVR 和 PD) 间的相关系数和互信息值, 此处以 MBVR 磨机负荷参数的 Ch1、Ch6 和 Ch8 通道为例, 如图 4 所示.



由图 4 和其他通道图可知, 基于相关系数和基于互信息的特征度量结果对不同模态机械频谱特征具有差异性, 并且采用不同阈值选择的特征子集也具有差异性.

依据本文所提方法, 基于相关系数值和互信息值的最小/最大值与各自均值的比值确定特征选择系数的上限和下限, 两者相差越大表明频谱特征间的差异越大.



本文以三个磨机负荷中的 PD 模型为例, 面向 PD 的不同模态频谱特征的特征选择系数统计结果如下表所示.

由表 1 可得到, 相关系数阈值的下限和上限分别为 0.8741 和 1.057, 互信息阈值的下限和上限分别为 0.9228 和 1.0599, 进而得到 PD 多模态特征选择的下限和上限分别为 0.9228 和 1.057.

通过三个磨机负荷参数的不同模态频谱特征的特征选择系数统计表可知, 不同模态针对不同磨机



(b) 模态 Ch6 的频谱变量与 MBVR 间的相关系数和互信息值
(b) Correlation coefficient and mutual information value between spectrum variable of mode Ch6 and MBVR



(c) 模态 Ch8 的频谱变量与 MBVR 间的相关系数和互信息值
(c) Correlation coefficient and mutual information value between spectrum variable of mode Ch8 and MBVR

图 4 模态 Ch1、Ch6、Ch8 的频谱变量与 MBVR 间的相关系数和互信息值



Fig. 4 Correlation coefficient and mutual information value between spectrum variable of mode Ch1、Ch6、Ch8 and MBVR

负荷参数选择的特征子集具有差异性, 基于这些特征子集构建线性和非线性子模型是非常必要的.

4.2.3 SEN 模型构建结果

本文中的线性建模方法为 PLS, 非线性建模方法为 RWNN, 采用验证数据集确定前者的潜变量个数和后者的隐层节点个数. 基于上述 2 个特征子集和 2 种建模方法, 组合得到的候选子模型类型为 4 种. 为便于后文统计, 对候选子模型的编码采用如表 2 所示的形式.

表 2 中: 在“子模型特点”列中, 前项表示特征类型, 后项表示子模型类型, 相应的“lin”和“non-



(a) 模态 Ch1 的频谱变量与 MBVR 间的相关系数和互信息值
(a) Correlation coefficient and mutual information value between spectrum variable of mode Ch1 and MBVR

表 1 面向 PD 的不同模态频谱特征的特征选择系数统计表
Table 1 Coefficients statistical table of different modal spectrum feature for PD

类别	Ch1	Ch2	Ch3	Ch4	Ch5	Ch6	Ch7	Ch8
线性特征选择系数Min	0.09050	0.007868	0.3678	0.005018	0.0001994	0.009596	0.002075	0.8741
线性特征选择系数Max	1.2897	1.7351	1.1913	1.3904	5.2883	1.2649	2.0564	1.0571
非线性特征选择系数Min	0.6644	0.5659	0.8813	0.8403	0.5718	0.7039	0.4860	0.9228
非线性特征选择系数Max	1.0715	1.0885	1.1680	1.1304	1.3556	1.1352	1.623	1.0599

表 2 候选子模型编码
Table 2 Coding of candidate sub-models

序号	子模型特点	子模型名称	子模型编码	多模态通道编号
1	lin_lin	Corr-PLS	1-8	1-Ch1, 2-Ch2, 3-Ch3, 4-Ch4, 5-Ch5, 6-Ch6, 7-Ch7, 8-Ch8
2	nonlin_lin	Mi-PLS	9-16	9-Ch1, 10-Ch2, 11-Ch3, 12-Ch4, 13-Ch5, 14-Ch6, 15-Ch7, 16-Ch8
3	lin_nonlin	Corr-RWNN	17-24	17-Ch1, 18-Ch2, 19-Ch3, 20-Ch4, 21-Ch5, 22-Ch6, 23-Ch7, 24-Ch8
4	nonlin_nonlin	Mi-RWNN	25-32	25-Ch1, 26-Ch2, 27-Ch3, 28-Ch4, 29-Ch5, 30-Ch6, 31-Ch7, 32-Ch8

lin”分别表示线性和非线性；在“子模型名称”列中，“Corr”和“Mi”分别表示相关系数和互信息。

针对不同 MLP，取特征选择系数的数量 J_{feature} 均为 10。采用不同特征选择系数所构建的 SEN 模型的预测误差和所选择的子模型编号如表 3 所示。

由表 3 可知：

1) MBVR 模型的最小预测误差为 0.04404，集成尺寸为 8，其集成子模型集合为 {25 17 18 27 22 19 30 24}，子模型的预测误差按照由高到低排序；结合表 2 可知，这些集成子模型的具体含义为 Mi-RWNN-Ch1, Corr-RWNN-Ch1, Corr-RWNN-Ch2, Mi-RWNN-Ch3, Corr-RWNN-Ch6, Corr-RWNN-Ch3, Mi-RWNN-Ch6, Corr-RWNN-Ch8；可见，线性特征-非线性子模型为 3 个，非线性特征-线性子模型为 5 个，表明基于相关系数构建的 RWNN

子模型性能更佳；模态通道为 Ch1、Ch2、Ch3、Ch6 和 Ch8，分别代表筒体振动、筒体振动、筒体振声、轴承振动和研磨区域振声，其中 Corr-RWNN-Ch8 具有最小的预测误差，表明不同模态特征蕴含的 MBVR 信息具有差异性。

2) PD 模型的最小预测误差为 0.01452，集成尺寸为 7，其集成子模型集合为 {22 14 24 32 26 19 30}，子模型的预测误差按照由高到低排序；结合表 2 可知，这些集成子模型的具体含义为 Corr-RWNN-Ch6, Mi-PLS-Ch6, Corr-RWNN-Ch8, Mi-RWNN-Ch8, Mi-RWNN-Ch2, Corr-RWNN-Ch3, Mi-RWNN-Ch6；可见，线性特征-非线性子模型为 3 个，非线性特征-线性子模型为 3 个，表明基于互信息提取特征子集构建的 RWNN 子模型性能更佳；模态通道为 Ch6、Ch8、

表 3 不同特征选择系数时所构建的 SEN 模型的预测误差和所选择的子模型编号
Table 3 Prediction error of SEN model with different feature selection coefficients and selected sub-model number

序号	MBVR		PD		CVR	
	测试误差	集成子模型编号	测试误差	集成子模型编号	测试误差	集成子模型编号
1	0.05330	{ 21 23 27 31 17 32 19 24 30 }	0.01579	{26 18 30}	0.01083	{14 19 26 18 30 22}
2	0.06204	{14 31 32 24 27 30}	0.01805	{25 10 31 32 14 19 24 18 30}	0.009697	{27 26 22 30}
3	0.04515	{9 17 26 14 30 27 22 32 19 24}	0.01855	{24 14 18 30 26}	0.01146	{27 14 19 26 31 18 30 22}
4	0.04717	{23 17 27 19 32 24 30}	0.01582	{14 24 26 27 32 30}	0.009544	{19 30 22}
5	0.05231	{27 17 30 23 19 32 24}	0.01843	{24 14 25 22 18 19 30}	0.01093	{20 14 31 27 32 19 26 22 30}
6	0.04433	{31 22 30 32 19 24}	0.01452	{22 14 24 32 26 19 30}	0.009930	{23 25 20 18 32 27 26 19 30 22}
7	0.05697	{31 32 24}	0.01627	{26 22 18 24 32 19 30}	0.009870	{6 20 28 19 32 18 26 27 22 30}
8	0.04459	{27 26 23 22 31 25 30 17 32 24}	0.01687	{27 18 32 19 30}	0.009280	{28 18 26 27 19 22 30}
9	0.04969	{26 32 27 30 25 19 24}	0.01718	{2 18 27 6 26 32 25 30}	0.009650	{18 32 26 25 27 19 30 22}
10	0.04624	{22 17 26 27 30 25 32 19 31 24}	0.01748	{25 26 22 32 27 6 18 19 30}	0.01212	{22 30}
11	0.04404	{25 17 18 27 22 19 30 24}	0.01769	{17 23 22 26 27 6 30 19 18}	—	—

表 4 磨机负荷参数各通道与多模态特征子集选择性集成模型的测试误差比较
Table 4 Comparison of test errors between various channels of mill load parameters and multi-modal feature subset SEN model

	RMSREs												备注
	MBVR				PD				CVR				
	Corr-PLS	Mi-PLS	Corr-RWNN	Mi-RWNN	Corr-PLS	Mi-PLS	Corr-RWNN	Mi-RWNN	Corr-PLS	Mi-PLS	Corr-RWNN	Mi-RWNN	
Ch1	0.1924	0.3426	0.1314	0.1503	0.06710	0.05411	0.06910	0.05161	0.05911	0.06622	0.07030	0.04930	筒体振动
Ch2	0.3213	0.7207	0.3103	0.1401	0.04221	0.04430	0.03321	0.03751	0.05650	0.04711	0.03711	0.02620	筒体振动
Ch3	0.4401	0.4431	0.09112	0.09020	0.12012	0.07611	0.03111	0.05210	0.1132	0.07831	0.02922	0.03810	筒体振声
Ch4	0.5125	0.4225	0.2822	0.2001	0.1142	0.08620	0.06460	0.1184	0.07442	0.06910	0.04110	0.04772	筒体振声
Ch5	0.4611	0.3409	0.1911	0.2221	0.1087	0.08122	0.1161	0.09810	0.09711	0.09610	0.04440	0.09911	轴承振动
Ch6	0.3105	0.2141	0.1431	0.1341	0.04410	0.03720	0.03520	0.02431	0.03520	0.03641	0.01630	0.01720	轴承振动
Ch7	0.3802	0.2502	0.1321	0.1101	0.1083	0.06241	0.06121	0.05611	0.09451	0.04811	0.04910	0.04141	轴承振动
Ch8	0.5934	0.6031	0.08090	0.3631	0.0971	0.07910	0.03310	0.03220	0.1421	0.08930	0.06840	0.03730	研磨振声
本文方法	0.04404				0.01452				0.00928				

Ch2 和 Ch3, 分别代表轴承振动、研磨区域振声、筒体振动和筒体振声, 其中 Mi-RWNN-Ch6 具有最小的预测误差, 表明不同模态特征蕴含的 PD 信息具有差异性, 并且主要存在机械振动模态频谱特征中。

3) CVR 模型的最小预测误差为 0.009280, 集成尺寸为 7, 其集成子模型集合为 {28 18 26 27 19 22 30}, 子模型的预测误差按照由高到低排序; 结合表 2 可知, 这些集成子模型的具体含义为 Mi-RWNN-Ch4、Corr-RWNN-Ch2、Mi-RWNN-Ch2、Mi-RWNN-Ch3、Corr-RWNN-Ch3、Corr-RWNN-Ch6、Mi-RWNN-Ch6; 可见, 线性特征-非线性子模型为 3 个, 非线性特征-非线性子模型为 4 个, 表明基于相关系数和互信息提取特征构建的 RWNN 子模型性能能够互补; 模态通道为 Ch4、Ch2、Ch3 和 Ch6, 分别代表筒体表面振声、筒体表面振动、筒体表面振声和轴承振动, 其中 Mi-RWNN-Ch6 具有最小的预测误差, 表明不同模态特征蕴含的 CVR 信息具有差异性, 主要存在机械振动和筒体表面振声频谱特征中。

4.2.4 实验结果比较

本文采用的是 8 个模态机械信号数据, 数据不同于其他已有磨机负荷预测方法. 因此, 此处进行单通道和本文所提方法的实验结果比较。

由表 4 和表 5 可知:

1) 本文所提方法针对 3 个磨机负荷参数的平均预测误差为 0.02260, 小于基于单通道的平均预测误差, 其中: Ch4 和 Ch5 的预测误差最大, 分别为 0.1019 和 0.1056, 其他 5 个通道的预测误差在 0.0501~0.0774 之间. 因此, 本文所提方法的预测性能比基于单通道的方法提升了 1 倍, 表明了所提方法的有效性。

表 5 磨机负荷参数各通道与多模态特征子集选择性集成模型的平均测试误差比较

Table 5 Average test errors comparison of the various channels of mill load parameters and multi-modal feature subset SEN model

通道	MBVR	PD	CVR	平均预测误差	备注
Ch1	0.1314	0.05161	0.04930	0.07740	筒体振动
Ch2	0.1401	0.03321	0.02620	0.06650	筒体振动
Ch3	0.09020	0.03111	0.02922	0.05020	筒体振声
Ch4	0.2001	0.06460	0.04110	0.1019	筒体振声
Ch5	0.1911	0.08122	0.04440	0.1056	轴承振动
Ch6	0.1341	0.02431	0.01630	0.05820	轴承振动
Ch7	0.1101	0.05611	0.04141	0.06920	轴承振动
Ch8	0.08090	0.03220	0.03730	0.05010	研磨振声
本文方法	0.04404	0.01452	0.00928	0.02260	

2) 不同通道的平均测试误差间具有差异性, 其中: 筒体振动 Ch1 和 Ch2 的预测误差差别较小, 筒体振声 Ch3 和 Ch4 的预测误差相差 2 倍, 筒体左侧轴承振动信号 Ch5 比右侧轴承振动信号 Ch6 和 Ch7 的预测误差大 2 倍, 研磨区域振声 Ch8 的预测误差较小, 这表明磨机不同位置的振动和振声信号中包含着不同的磨机负荷参数信息, 采用不同通道的多模态信号有助于实现磨机负荷参数的准确测量; 此外, Ch4 和 Ch5 预测误差远高于其他通道, 表明这两个通道可能存在故障。

3) 同一 MLP 在不同机械通道上的测试误差具有差异性, 其中: 针对 MBVR, Ch8 的测试误差最小, 仅为 0.08090, 而 Ch4 的最大, 为 0.2001, 两者相差 2 倍. 针对 PD, Ch6 的测试误差最小, 为 0.02431, Ch5 的最大, 为 0.08122, 相差近 4 倍; 针对 CVR, Ch6 的测试误差最小, 为 0.01630, Ch1 的

最大为 0.04930, 相差 3 倍. 此外, 针对 PD 和 CVR, Ch6 通道均具有最佳的测试误差. 上述结果表明, 针对同一个 MLP 而言, 各模态信号特征之间的确存在冗余性和互补性, 进行多模态信号频谱特征的选择与融合是合理的.

4) 同一模态 (通道) 针对不同 MLP 的测试误差具有差异性: 针对 MBVR 的预测误差均高于 PD 和 CVR, 如 Ch3 的 MBVR 预测误差为 0.09020, PD 和 CVR 预测误差分别为 0.03111 和 0.02922, 相差近 3 倍, 说明各个通道对不同磨机负荷参数的敏感度不同; 但是, 这也可能与所采用的实验磨机的特性是相关的. 显然, 这需要进行更为深入的实验研究.


5 结论

针对多模态高维机械频谱数据输入特征与 MLP 间的可解释映射模型难以构建的难题, 本文提出了基于多模态特征异质模型集成的 MLPF 方法. 主要贡献表现在: 能够依据多模态频谱数据特性进行线性特征子集和非线性特征子集的自适应选择, 提出构建线性特征线性子模型、线性特征非线性子模型、非线性特征线性子模型、非线性特征非线性子模型的策略增强集成子模型间的差异性, 提出了多模态频谱子模型的自适应选择与合并方法. 通过磨矿过程实验球磨机的高维机械振动和振声频谱数据仿真验证了所提方法的有效性.

References

- Zhou P, Chai T-Y, Wang H. Intelligent optimal-setting control for grinding circuits of mineral processing. *IEEE Transactions on Automation Science and Engineering*, 2009, **6**(4): 730-743
- Chai Tian-You. Operational optimization and feedback control for complex industrial processes. *Acta Automatica Sinica*, 2013, **39**(11): 1744-1757
(柴天佑. 复杂工业过程运行优化与反馈控制. 自动化学报, 2013, **39**(11): 1744-1757)
- Kano M, Fujiwara K. Virtual sensing technology in process industries: Trends & challenges revealed by recent industrial applications. *Journal of Chemical Engineering of Japan*, 2013, **46**(1): 1-17
- Tang Jian, Zhao Li-Jie, Yue Heng, Chai Tian-You. Present status and future developments of detection method for mill load. *Control Engineering of China*, 2010, **17**(5): 565-570
(汤健, 赵立杰, 岳恒, 柴天佑. 磨机负荷检测方法研究综述. 控制工程, 2010, **17**(5): 565-570)
- Tang Jian, Qiao Jun-Fei, Liu Zhuo, Zhou Xiao-Jie, Yu Gang, Zhao Jian-Jun. Review of ball mill grinding mechanism numerical simulation and mill load parameters soft measurement for mineral grinding process. *Journal of Beijing University of Technology*, 2018, **44**(11): 1459-1470
(汤健, 乔俊飞, 刘卓, 周晓杰, 余刚, 赵建军. 磨矿过程球磨机研磨机理数值仿真及磨机负荷参数软测量综述. 北京工业大学学报, 2018, **44**(11): 1459-1470)
- Baltrusaitis T, Ahuja C, Morency L P. Multimodal machine learning: A survey and taxonomy. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2019, **41**(2): 423-443
- Huang P, Jia M P, Zhong B L. Investigation on measuring the fill level of an industrial ball mill based on the vibration characteristics of the mill shell. *Minerals Engineering*, 2009, **14**: 1200-1208
- Das Sarada P, Das Debi P, Behera S K, Mishra B K. Interpretation of mill vibration signal via wireless sensing. *Minerals Engineering*, 2011, **24**: 245-251
- Feng Tian-Jing, Wang Huan-Gang, Xu Wen Li, Xu Ning. An online mill load monitoring system based on shell vibration signals. *Mining & Metallurgy*, 2010, **19**(2): 66-69
(冯天晶, 王焕钢, 徐文立, 徐宁. 基于筒壁振动信号的磨机工况监测系统. 矿冶, 2010, **19**(2): 66-69)
- Tang Jian, Qiao Jun-Fei, Chai Tian-You, Liu Zhuo, Wu Zhi-Wei. Modeling multiple components mechanical signals by means of virtual sample generation technique. *Acta Automatica Sinica*, 2018, **44**(9): 1569-1589
(汤健, 乔俊飞, 柴天佑, 刘卓, 吴志伟. 基于虚拟样本生成技术的多组分机械信号建模. 自动化学报, 2018, **44**(9): 1569-1589)
- Tang Jian, Tian Fu-Qing, Jia Mei-Ying, Li Dong. *Soft Measurement of Rotating Machinery Equipment Load Based on Spectrum Data Drive*. Beijing: National Defense Industry Press, 2015.
(汤健, 田福庆, 贾美英, 李东. 基于频谱数据驱动的旋转机械设备负荷软测量. 北京: 国防工业出版社, 2015.)
- Hasnat A, Molla A U. Feature selection in cancer microarray data using multi-objective genetic algorithm combined with correlation coefficient. In: Proceedings of Emerging Technological Trends (ICETT), International Conference on. IEEE, 2016: 1-6
- Coelho F, Braga A P, Verleysen M. Multi-objective semi-supervised feature selection and model selection based on Pearson's correlation coefficient. In: Proceedings of Iberoamerican Congress Conference on Progress in Pattern Recognition. Springer-Verlag, 2010.
- Malji P, Sakhare S. Significance of entropy correlation coefficient over symmetric uncertainty on FAST clustering feature selection algorithm. In: Proceedings of 11th International Conference on Intelligent Systems and Control (ISCO). IEEE, 2017: 457-463.
- Vergara J R, Estévez P A. A review of feature selection methods based on mutual information. *Neural Computing and Applications*, 2014, **24**(1): 175-186
- Battiti R. Using mutual information for selecting features in supervised neural net learning. *IEEE Transactions on Neural Networks*, 1994, **5**(4): 537-550
- Jain A K, Duin R P W, Mao J. Statistical pattern recognition: A review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2000, **22**(1): 4-37
- Fleuret F. Fast binary feature selection with conditional mutual information. *Journal of Machine Learning Research*, 2004, **5**(11): 1531-1555
- Gavin Brown, Jeremy Wyatt, Rachel Harris, Xin Yao. Diversity creation methods: A survey and categorisation. *Information Fusion*, **6**(2005): 5-20
- Tang J, Chai T Y, Yu W, Liu Z, Zhou X J. A Comparative study that measures ball mill load parameters through different single-scale and multi-scale frequency spectra-based approaches. *IEEE Transactions on Industrial Informatics*, 2016, **12**(6): 2008-2019
- Tang Jian, Chai Tian-You, Cong Qiu-Mei, Liu Zhuo, Yu Wen. Modeling mill load parameters based on selective fusion of multi-scale shell vibration frequency spectra. *Control theory & Applications*, 2015, **32**(12): 1582-1591
(汤健, 柴天佑, 丛秋梅, 刘卓, 余文. 选择性融合多尺度筒体振动频

- 谱的磨机负荷参数建模. 控制理论与应用, 2015, **32**(12): 1582-1591)
- 22 Tang J, Qiao J F, Wu Z W, Chai T Y, Zhang J, Yu W. Vibration and acoustic frequency spectra for industrial process modeling using selective fusion multi-condition samples and multi-source features. *Mechanical Systems & Signal Processing*, 2018, **99**: 142-168
- 23 Pao Y H, Takefuji Y. Functional-link net computing: theory, system architecture, and functionalities. *Computer*, 1992, **25**(5): 76-79
- 24 Pao Y H, Park G H, Sobajic D J. Learning and generalization characteristics of the random vector functional-link net. *Neuro-computing*, 1994, **6**(2): 163-180
- 25 Tang Jian, Zhao Li-Jie, Chai Tian-You, Yue Heng. On-line soft-sensing modelling of mill load based on vibration spectrum. *Information and Control*, 2012, **41**(1): 123-128
(汤健, 赵立杰, 柴天佑, 岳恒. 基于振动频谱的磨机负荷在线软测量建模. 信息与控制, 2012, **41**(1): 123-128)
- 26 He Min, Tang Jing, Guo Xu-Qi, Yan Gao-Wei. Soft sensor for ball mill load based on DAMRRWNN model. *Acta Automatica Sinica*, 2019, **45**(2): 398-406
(贺敏, 汤健, 郭旭琦, 阎高伟. 基于流形正则化域适应随机神经网络湿式球磨机负荷参数软测量. 自动化学报, 2019, **45**(2): 398-406)
- 27 Yan Gao-Wei, He Min, Tang Jian, Han Dong-Sheng. Soft sensor of wet ball mill load based on maximum mean discrepancy multi-source domain transfer learning. *Control and Decision*, 2018, **33**(10): 1795-1800
(阎高伟, 贺敏, 汤健, 韩东升. 基于最大均值差异多源域迁移学习的湿式球磨机负荷参数软测量. 控制与决策, 2018, **33**(10): 1795-1800)
- 28 Tang Jian, Qiao Jun-Fei, Liu Zhuo, Zhou Xiao-Jie, Yu Gang, Zhao Jian-Jun. Multi-channel mechanical signal analytical estimation and optimal combination method for mill load parameter forecasting. *Journal of Beijing University of Technology*, 2020, **46**(9): 997-1007
(汤健, 乔俊飞, 刘卓, 周晓杰, 余刚, 赵建军. 面向磨机负荷参数预测的多通道机械信号分析评估与优化组合. 北京工业大学学报, 2020, **46**(9): 997-1007)
- 29 Zhao Xuan, Guo Wei, Liu Jing. Object detection adopting sub-step merging of super-pixel and multi-modal fusion in RGB-D. *Journal of Image and Graphics*, 2018, **23**(8): 1231-1241
(赵轩, 郭蔚, 刘京. RGB-D图像中的分步超像素聚合和多模态融合目标检测. 中国图象图形学报, 2018, **23**(8): 1231-1241)
- 30 Ma Jiang-He, Sun Ying, Zhang Xue-Ying. Multimodal emotion recognition for the fusion of speech and EEG signals. *Journal of Xidian University*, 2019, **46**(1): 143-150
(马江河, 孙颖, 张雪英. 融合语音信号和脑电信号的多模态情感识别. 西安电子科技大学学报, 2019, **46**(1): 143-150)
- 31 Dahne S, Biebmam F, Samek W, et al. Multivariate machine learning methods for fusing multimodal functional neuroimaging data. *Proceedings of the IEEE*, 2015, **103**(9): 1-24
- 32 Ramachandram D, Taylor G W. Deep multimodal learning: A survey on recent advances and trends. *IEEE Signal Processing Magazine*, 2017, **34**(6): 96-108
- 33 Wu D, Pigou L, Kindermans P J, et al. Deep dynamic neural networks for multimodal gesture segmentation and recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, **38**(8): 1583-1597



刘卓 东北大学流程工业综合自动化国家重点实验室讲师. 主要研究方向为复杂工业过程建模.

E-mail: liuzhuo@ise.neu.edu.cn

(LIU Zhuo Lecturer at the State Key Laboratory of Synthetical Automation for Process Industries of Northeastern University. Her research interest covers modeling for complex industries.)



汤健 北京工业大学教授. 主要研究方向为小样本数据建模, 城市固废自动化处理. 本文通信作者.

E-mail: freeflytang@bjut.edu.cn


(TANG Jian Professor at Beijing University of Technology. His research interest covers small sample data modeling and intelligent automatic processing of municipalsolid. Corresponding author of this paper.)



柴天佑 中国工程院院士, 东北大学教授. IEEE Fellow, IFAC Fellow, 欧亚科学院院士. 主要研究方向为自适应控制, 智能解耦控制, 流程工业自动化理论、方法与技术.

E-mail: tychai@mail.neu.edu.cn

(CHAI Tian-You Academician of Chinese Academy of Engineering, professor at Northeastern University, IEEE Fellow, IFAC Fellow, and Academician of the International Eurasian Academy of Sciences. His research interest covers adaptive control, intelligent decoupling control, and integrated automation theory, method and technology of industrial process.)



余文 墨西哥国立理工大学高级研究中心自动化部教授. 主要研究方向为复杂工业过程建模与控制, 机器学习. E-mail: yuw@ctrl.cinvestav.mx

(YU Wen Professor in the Departamento de Control Automatico of the Centro de Investigacion de Estudios Avanzados, National Polytechnic Institute Mexico. His research interest covers modeling and control of the complex industrial process, and machine learning.)