

文章编号: 1671-251X(2025)02-0106-07

DOI: [10.13272/j.issn.1671-251x.2024090053](https://doi.org/10.13272/j.issn.1671-251x.2024090053)

# 基于单分类支持向量机的煤矿防爆电气设备 振动故障自动检测

郑铁华<sup>1</sup>, 王飞<sup>1</sup>, 赵格兰<sup>2</sup>, 杜春晖<sup>3</sup>

(1. 国家能源集团神东煤炭集团有限责任公司, 陕西 神木 719315; 2. 中国煤炭科工集团信息技术有限公司,  
陕西 西安 710054; 3. 山西天地煤机装备有限公司, 山西 太原 030006)

**摘要:** 煤矿防爆电气设备在运行过程中产生的振动会损害其机械完整性, 导致紧固件松动、零部件磨损, 并改变设备的结构与振动模态, 进而引发信号特征的复杂变化, 使得正常振动频率与故障引发的新频率成分相互混淆, 模糊了正常信号与故障信号之间的界限, 从而降低传统检测方法在故障检测中的准确性。针对上述问题, 提出一种基于单分类支持向量机(OCSVM)的煤矿防爆电气设备振动故障自动检测方法。首先, 构造设备的正常状态特征和振动故障状态特征, 根据OCSVM的特性, 将正常状态特征序列设定为OCSVM核函数的决策边界学习目标。考虑煤矿防爆电气设备振动故障信号呈现非线性和高维特征, 选定多项式核作为OCSVM的核函数。然后, 采用网格搜索和K-交叉验证相结合的方式对OCSVM进行参数调优, 以使OCSVM达到更好的性能。最后, 通过求取OCSVM目标函数的最优解, 确定最优决策边界, 以此实现煤矿防爆电气设备振动故障的自动检测。实验结果显示: ①在迭代次数为20时, OCSVM算法算法可完成收敛, 达到稳定。②基于OCSVM的电气设备信号划分实验中, 借助多项式核函数能精准划分样本实现检测。③振动故障自动检测性能分析中, 所提方法在各样本量下准确率均显著高于红外热成像技术检测方法、基于灰狼优化支持向量机模型检测方法, 小样本量时准确率达98.25%且稳定性好。

**关键词:** 煤矿防爆电气设备; 振动故障检测; 单分类支持向量机; 变分模态分解; 熵矩阵

中图分类号: TD684

文献标志码: A

Automatic vibration fault detection of coal mine explosion-proof electrical equipment based on  
One-Class Support Vector Machine

ZHENG Tiehua<sup>1</sup>, WANG Fei<sup>1</sup>, ZHAO Gelan<sup>2</sup>, DU Chunhui<sup>3</sup>

(1. CHN Energy Shendong Coal Group Co., Ltd., Shenmu 719315, China; 2. CCTEG Information Technology Co.,  
Ltd., Xi'an 710054, China; 3. Shanxi Tiandi Coal Mining Machinery Co., Ltd., Taiyuan 030006, China)

**Abstract:** The vibration generated by explosion-proof electrical equipment in coal mines during operation can compromise its mechanical integrity, leading to fastener loosening, component wear, and changes in the structure and vibration modes of the equipment. This can cause complex changes in signal features, resulting in confusion between normal vibration frequency and new frequency components induced by faults. As a result, the boundary between normal and fault signals becomes unclear, reducing the accuracy of traditional fault detection methods. To address this issue, an automatic vibration fault detection method for coal mine explosion-proof electrical equipment was proposed based on One-Class Support Vector Machine (OCSVM). First, the normal state features and vibration fault state features of the equipment were constructed. Based on the characteristics of

收稿日期: 2024-09-14; 修回日期: 2025-01-16; 责任编辑: 王晖, 郑海霞。

基金项目: 山西省重点研发计划项目(202102100401014)。

作者简介: 郑铁华(1978—), 男, 吉林东丰人, 工程师, 硕士, 研究方向为矿业工程, E-mail: [10020946@ceic.com](mailto:10020946@ceic.com)。

引用格式: 郑铁华, 王飞, 赵格兰, 等. 基于单分类支持向量机的煤矿防爆电气设备振动故障自动检测[J]. 工矿自动化, 2025, 51(2): 106-112.

ZHENG Tiehua, WANG Fei, ZHAO Gelan, et al. Automatic vibration fault detection of coal mine explosion-proof electrical equipment based on One-Class Support Vector Machine[J]. Journal of Mine Automation, 2025, 51(2): 106-112.



扫码移动阅读

OCSVM, the normal state feature sequence was set as the learning target for the decision boundary of the OCSVM kernel function. Due to the nonlinear and high-dimensional characteristics of vibration faults in explosion-proof electrical equipment, a polynomial kernel was selected as the OCSVM kernel function after comprehensive consideration. Then, grid search combined with K-fold cross-validation was used to optimize the parameters of the OCSVM, ensuring better performance. Finally, by obtaining the optimal solution of the OCSVM objective function, the optimal decision boundary was determined to realize automatic fault detection of vibration faults in coal mine explosion-proof electrical equipment. Experimental results showed that: ① When the number of iterations is 20, the OCSVM algorithm can complete convergence and achieve stability. ② In the electrical equipment signal classification experiment based on OCSVM, the use of the polynomial kernel function accurately classified samples for detection. ③ In the performance analysis of automatic vibration fault detection, the proposed method showed significantly higher accuracy across different sample sizes than infrared thermography and detection methods based on grey wolf optimization and support vector machine. Under small sample sizes, it achieved an accuracy of 98.25% with good stability.

**Key words:** coal mine explosion-proof electrical equipment; vibration fault detection; One-Class Support Vector Machine; variational mode decomposition; entropy matrix

## 0 引言

煤矿井下环境具有高湿度、高粉尘、高温和高压等特点,对防爆电气设备的稳定运行提出了严峻挑战<sup>[1]</sup>。在这种环境下,防爆电气设备不仅要承受常规的电力负荷,还要应对各种物理和化学因素的影响。煤矿开采过程中,防爆电气设备的运行和岩层的移动都会产生振动,这些振动传递到电气设备上,易导致设备内部的紧固件松动或零部件磨损(紧固件松动可能导致电气设备接触不良,零部件磨损会引起信号传输路径的变化),从而改变设备的机械结构,导致信号波动或失真<sup>[2-3]</sup>,使正常信号和故障信号之间的界限变得模糊,增加了故障检测的难度。为了确保煤矿安全生产,减少因电气设备振动故障引发的事故,需要开发能够适应煤矿井下复杂环境的振动故障自动检测技术。

在电气设备故障检测领域,国内外学者和工程技术人员已经进行了大量的研究和实践工作。文献[4]利用红外热成像技术对电气设备进行状态监测,将被检对象的不规则区域反映为异常区域,检测中压装置电气设备的故障,但红外热像仪的穿透力不强,对温差有依赖性,且会受到煤矿复杂环境中温度、湿度、粉尘等因素的干扰,影响检测。文献[5]提出基于灰狼优化支持向量机模型,采集常见家用线性和非线性电气正常及电弧故障波形信号并进行频域特征提取,实现电气设备的故障检测,但将故障信号的频域特征作为灰狼优化支持向量机模型的输入来实现故障检测会丢失部分时域信息,无法准确反映设备状态。文献[6]基于非子采样剪切波变换和自适

应脉冲耦合神经网络,通过对比、融合设备的红外图像与可见光图像,完成故障检测,但2种图像的物理特性和成像条件存在较大差异,特征匹配精度较低,进而导致故障检测不准确。文献[7]将蜻蜓算法-蚁群优化技术与尖峰神经网络模型进行融合,依据蜻蜓算法-蚁群优化技术所提取的特征,借助尖峰脉冲序列来实现对电气设备故障的检测,但蜻蜓算法-蚁群优化技术存在算法复杂、参数调优难、局部最优等问题,影响检测性能。文献[8]基于UNet网络和深度残差网络,根据电气设备红外图像的分割结果完成故障检测,但深度残差网络的冗余层会增加模型的复杂性和计算成本,减少图像的有效感受野,降低检测效率。

针对现有研究存在受环境因素干扰大、信息丢失、特征匹配精度低、算法复杂且优化困难、模型复杂导致计算成本高等问题,本文提出一种基于单分类支持向量机(One-Class Support Vector Machine, OCSVM)的煤矿防爆电气设备振动故障自动检测方法。该方法围绕设备正常与故障状态特征构造、核函数选择、参数调优及最优决策边界确定等步骤展开,以实现对煤矿防爆电气设备振动故障的精准自动检测。

## 1 方法原理

首先,采用网格搜索算法结合K-交叉验证对OCSVM的参数进行寻优操作,找到一组最优的参数组合,使OCSVM能够以最佳的性能状态来处理数据。然后,在经过优化后的OCSVM模型中,利用正常状态下防爆电气设备的信号样本进行训练,自动

检测出设备的振动故障。最后,针对煤矿井下环境中信号特征复杂的特点,进一步调整 OCSVM 的关键参数,让模型更好地适应环境,从而提高振动故障检测的准确性。

### 1.1 防爆电气设备信号特征划分

变分模态分解(Variational Mode Decomposition, VMD)作为一种有效的信号处理方法,能够通过对信号特征的精细剖析,将复杂信号分解成一系列固有模态函数(Intrinsic Mode Functions, IMF)<sup>[9]</sup>,每个 IMF 代表信号的一个特定频率分量。在进行 VMD 时,IMF 分量个数  $M$  的确定需要综合考虑信号的复杂度、采样频率及期望分析的频率分辨率等因素。通常采用基于中心频率估计法确定  $M$ ,假设原始信号经过离散化后得到离散信号,其傅里叶变换结果为  $\hat{x}(f)$ ,  $f$  为估计信号。首先,对信号的频谱进行初步分析,估计信号主要频率成分的数量和分布范围。如果信号的频谱在某个频段内呈现出  $N$  个明显的峰值,且这些峰值之间的间隔相对较大,则将  $M$  设定为接近  $N$  的值。然后,对  $M$  ( $M = \left\lfloor \frac{f_s}{2\Delta f} \right\rfloor$ , 其中  $f_s$  为采样频率,  $\Delta f$  为期望的频率分辨率) 进一步调整。在确定频率分辨率时,需要考虑信号中不同频率成分的间隔及分析的精度要求。最后,通过 VMD 用 IMF 描述设备信号。结合 IMF 混叠密度和皮尔逊相关系数<sup>[10]</sup>,可得界定函数:

$$\eta(f) = \frac{\int_{-\infty}^{\infty} |X_M(f)|^2 \Delta f}{\int_{-\infty}^{\infty} |X(f)|^2 \Delta f} \quad (1)$$

$$\rho = \frac{\sum_{i=1}^n (l_i - \bar{l})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (l_i - \bar{l})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (2)$$

$$A = \int_{-\infty}^{\infty} |X_M(f) - X(f)|^2 \Delta f \quad (3)$$

式中:  $\eta(f)$  为运行信号的频域模态混叠密度;  $X_M(f)$ ,  $X(f)$  为由相邻的 2 个 IMF 经傅里叶变换得到的频域函数;  $\rho$  为重构信号与初始信号的相关系数;  $l_i$  和  $y_i$  分别为重构信号和初始信号的第  $i$  个样本点;  $\bar{l}$  和  $\bar{y}$  分别为  $l_i$  和  $y_i$  的平均值;  $A$  为频率对应的幅值与频率的频域函数中心频率处幅值的重叠面积。

煤矿防爆电气设备表现出复杂的非线性行为,相空间重构方法适用于分析非线性系统,能够更好地捕捉系统的非线性特征,从而提高振动故障检测的准确性。已知防爆电气设备运行信号序列为  $S = \{s_1, s_2, \dots, s_j\}$ ,  $s_j$  为第  $j$  个防爆电气设备运行信

号,则基于界定函数的信号相空间重构矩阵为

$$S = \begin{bmatrix} s_1 & s_2 & \cdots & s_{1+w\tau-\tau} \\ s_2 & s_3 & \cdots & s_{2+w\tau-\tau} \\ \vdots & \vdots & & \vdots \\ s_j & s_{j+1} & \cdots & s_{j+w\tau-\tau} \end{bmatrix} \quad (4)$$

式中:  $s_1$  为第 1 个防爆电气设备运行信号;  $s_{1+w\tau-\tau}$  为  $S = \{s_1, s_2, \dots, s_j\}$  中按照相空间重构规则确定的一个特定位置的信号值,  $w$  为嵌入维数,  $\tau$  为延迟时间。

通过延迟时间和嵌入维数可以有效重构出煤矿防爆电气设备信号的动态相空间。采用互信息法选择延迟时间,使信号与自身延迟之间的互信息达到最小。当互信息最小时,意味着该延迟时间既能保持信号内部的相关性,保证重构后的相空间能够反映原信号的动态特性,又能最大程度地减少冗余信息,避免信息的重复和干扰。采用虚假最近邻法确定嵌入维数,通过检查随着嵌入维数增加,原本接近的点是否仍然保持接近来确定足够的嵌入维数,以揭示系统的真实动态行为。经过信号相空间重构,得到  $w$  维相空间映射下的正常状态特征序列和振动故障状态特征序列<sup>[11]</sup>。设正常状态特征序列为  $\{a_1, a_2, \dots, a_n\}$ , 振动故障状态特征序列为  $\{b_1, b_2, \dots, b_n\}$ ,  $a_i$  和  $b_i$  分别为第  $i$  个正常和故障特征信号经过归一化处理后的熵值。对熵值进行归一化处理,能够在统一的尺度下对正常状态和故障状态特征进行比较和分析。

为进一步量化正常状态和振动故障状态之间的差异,采用熵矩阵  $Y$  揭示煤矿防爆电气设备信号在正常和振动故障状态下表现出的差异<sup>[12]</sup>,以实现对防爆电气设备信号特征的划分,并将熵值变化明显的特征作为振动故障检测的关键特征。

$$Y = \begin{bmatrix} e_{11} & e_{12} \\ e_{21} & e_{22} \end{bmatrix} \quad (5)$$

式中:  $e_{11}$  为正常状态特征序列的熵值统计量;  $e_{12}$  为正常状态特征序列与振动故障状态特征序列之间的熵值关联量;  $e_{21}$  为正常状态特征序列的熵值统计量;  $e_{22}$  为正常状态特征序列与振动故障状态特征序列之间的熵值关联量。

### 1.2 防爆电气设备振动故障自动检测

通过分析熵矩阵,可将信号的复杂性量化,从而更好地理解和区分正常和振动故障信号。然而,由于煤矿井下环境的复杂性,即使有了熵矩阵,正常和振动故障状态特征信号之间的界限仍然不够清晰。为了实现对防爆电气设备振动故障的自动检测,采

用OCSVM在高维特征空间中找到一个最优的决策边界,并将获取的正常状态特征作为OCSVM核函数的学习目标。

核函数是OCSVM复杂度和泛化能力的决定性因素。采用线性核函数<sup>[13]</sup>分隔线性可分数据,将不可分数据核映射<sup>[14]</sup>至高维空间后再进行线性划分。因此,根据煤矿防爆电气设备振动故障的非线性和高维特征特点,结合不同核函数的分隔方式,选取多项式核<sup>[15]</sup>作为OCSVM的核函数。

多项式核能够有效处理非线性关系和高维特征,且具有较好泛化能力。已知多项式核的独立项 $g_H$ 、偏移项 $c_H$ 和多项式的度数 $d$ ,则OCSVM的核函数为

$$H(z_i, z_j) = \left[ \frac{g_H(z_1 \times z_2) + c_H}{g_H \|z_1 + z_2\| + c_H} \right]^d \quad (6)$$

式中: $\langle z_1 \times z_2 \rangle$ 为输入向量 $z_1$ 和 $z_2$ 在初始空间中的内积运算; $\|z_1 + z_2\|$ 为输入向量 $z_1$ 和 $z_2$ 对应元素相加后所得向量的模长。

采用OCSVM检测煤矿防爆电气设备振动故障时,模型参数对性能影响重大,不合理的参数选择会导致过拟合或欠拟合,影响故障检测效果。为找到最优参数组合,采用网格搜索和K-交叉验证方法实施参数调优,以实现OCSVM的最佳性能。网格搜索能够遍历所有可能的参数组合,找到最优解;K-交叉验证<sup>[16-17]</sup>则可以有效避免评估偏差。因此,结合这2种方法,可以更有效地优化OCSVM的参数,提高故障检测的准确性。煤矿防爆电气设备振动故障自动检测方法步骤如下。

1)首先,初始化OCSVM的参数范围和寻优步长,同时指定训练样本集和交叉验证的 $K$ 值。分割参数为网格,按照各参数的寻优步长,在极限内进行搜索,遍历各参数的所有可能值。

2)对训练样本集进行划分操作,将其划分为 $K$ 个互不相交的子集,这些子集将用于交叉验证,每个子集都只作为一次验证集。循环遍历每一折样本,令当前折为验证集,其余所有折合并作为训练集。使用当前折的验证集和其余折合并后的训练集训练OCSVM,并计算验证精确率 $B_k$ 。在完成所有折的验证后,求解所有 $B_k$ 的均值,得到平均验证精确率 $\bar{B}_k$ 。

3)循环以上步骤直到 $\bar{B}_k$ 不再增加,则对应的参数组合即为OCSVM的最佳参数组合,完成OCSVM参数调优。

4)将构造的正常状态特征序列作为OCSVM核函数的决策边界学习目标,通过求解目标函数 $W_{\text{ocsvm}}$ ,

在高维空间内找到最优的决策边界。

$$W_{\text{ocsvm}} = \min \left\{ \frac{\|\delta\|^2}{2} + \frac{\xi}{pm} - L \right\} \quad (7)$$

式中: $\delta$ 、 $L$ 分别为决策边界的法向量和截距; $\xi$ 为松弛系数; $p$ 为边界支持向量率的上限; $m$ 为训练样本数。

根据拉格朗日对偶理论<sup>[18-19]</sup>,结合拉格朗日乘子 $\alpha$ ,设立 $W_{\text{ocsvm}}$ 的对偶问题:

$$\max \min J(\delta, \xi, L, \alpha) :$$

$$\max \min J(\delta, \xi, L, \alpha) = W_{\text{ocsvm}} - \alpha [\delta \phi(x_i) - L + \xi] \quad (8)$$

式中 $\phi(x_i)$ 为信号 $x_i$ 的非线性映射函数。

分别对 $\delta$ 、 $L$ 、 $\xi$ 求偏导数并置零,将置零偏导数后的条件代入式(8),得到 $W_{\text{ocsvm}}$ 的最优解:

$$W_{\text{ocsvm}}^{\text{best}} = \frac{\operatorname{sgn}[aH(x_i, x_i) - P']}{\max \min J(\delta, \xi, L, \alpha)} \quad (9)$$

式中 $P'$ 为OCSVM高维决策阈值参数。

5)依据基于拉格朗日对偶理论求解最优解的过程中得出的 $P'$ 确定高维空间内的最优决策边界<sup>[20-21]</sup>,根据下式辨识信号 $x_i$ 类别,实现OCSVM对防爆电气设备振动故障的自动检测。

$$\begin{cases} P' - \delta \phi(x_i) < 0, & \text{正常} \\ P' - \delta \phi(x_i) \geq 0, & \text{故障} \end{cases} \quad (10)$$

## 2 实例验证

### 2.1 实验准备

本文选取YBX3-132S-4隔爆型三相异步电动机作为待检测目标,其技术参数见表1。

表1 矿用防爆电动机技术参数

Table 1 Technical specification of mine explosion-proof motor

参数	值	参数	值
额定电压/V	380	同步转速/(r·min <sup>-1</sup> )	1 440
额定电流/A	11.37	额定转速/(r·min <sup>-1</sup> )	1 460
额定频率/Hz	50	效率/%	89.6
额定功率/kW	5.5	功率因数	0.82
额定转矩/(N·m)	36.48	电源频率/Hz	50

采用高精度加速度传感器,采样频率设置为5 120 Hz,以捕捉设备在不同工况下的微小振动变化。振动数据通过三轴加速度计同时采集。使用热敏电阻温度传感器,采样频率设为1 Hz,用于监测设备关键部件的温度变化,预防过热导致的故障。通过电流互感器和电压分压器采集电气信号,采样频率为100 Hz,用于分析设备的电气性能,如电动机负载情况、电源稳定性等。采用麦克风或声级计,采样

频率为 44 100 Hz, 用于捕捉设备运行中的异常声响, 如轴承磨损、齿轮啮合不良等声音特征。实验工况设置: ① 设备在额定负载下连续运行 24 h, 每隔 1 h 记录 1 次数据, 包括上述所有类型的信号。② 将设备负载调整至额定负载的 50%, 运行 4 h, 同样每隔 1 h 记录 1 次数据。③ 将设备负载增加至额定负载的 120% (确保在安全范围内), 运行 2 h, 每隔 30 min 记录 1 次数据, 以观察设备在高负荷下的表现。在不同负载工况的数据采集过程中, 除了上述各种负载条件下的数据记录, 还需分别记录设备从静止到全速运行(启动)和从全速运行到静止(停止)的过程。每个过程持续 1 min, 采样频率调整为 10 000 Hz, 以捕捉瞬态变化。将采集到的数据进行预处理, 以提高数据质量, 确保数据具有可靠的使用性。使用预处理后的正常状态数据训练 OCSVM, 学习设备的正常状态边界。调优后的参数: 权衡因子为 0.002, 缓存大小为 349 MiB, 最多迭代 284 次, 收敛容忍度为 1; 多项式核函数中, 独立项为 100, 偏移项为 1, 多项式度数为 15。

将自动检测方法编程为 OCSVM 算法集成到电气设备振动故障监测装置中, 使其能够自动识别和报告设备的异常状况, 以实现对隔爆型三相异步电动机振动故障的自动检测。

## 2.2 OCSVM 性能验证

对 OCSVM 算法性能进行验证, 结果如图 1 所示。可看出随着迭代次数的递增, 算法逐渐趋近收敛状态, 在迭代次数为 20 时, 通过网络搜索算法结合 K-交叉验证进行参数寻优后的 OCSVM 算法可完成收敛, 达到稳定。

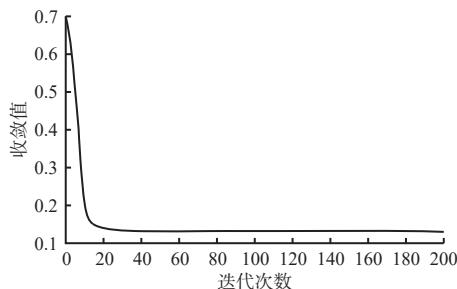


图 1 OCSVM 性能验证结果

Fig. 1 OCSVM performance verification results

## 2.3 基于 OCSVM 的电气设备信号划分

利用 OCSVM 实现对电气设备信号的有效划分, 进而检测隔爆型三相异步电动机的振动故障, 信号划分结果如图 2 所示。

从图 2(a)可看出, 振动故障信号呈现出较为复杂且不规则的波动形态, 其幅值在时间轴上不断变化, 波动幅度较大且频繁。这些特征表明设备的振

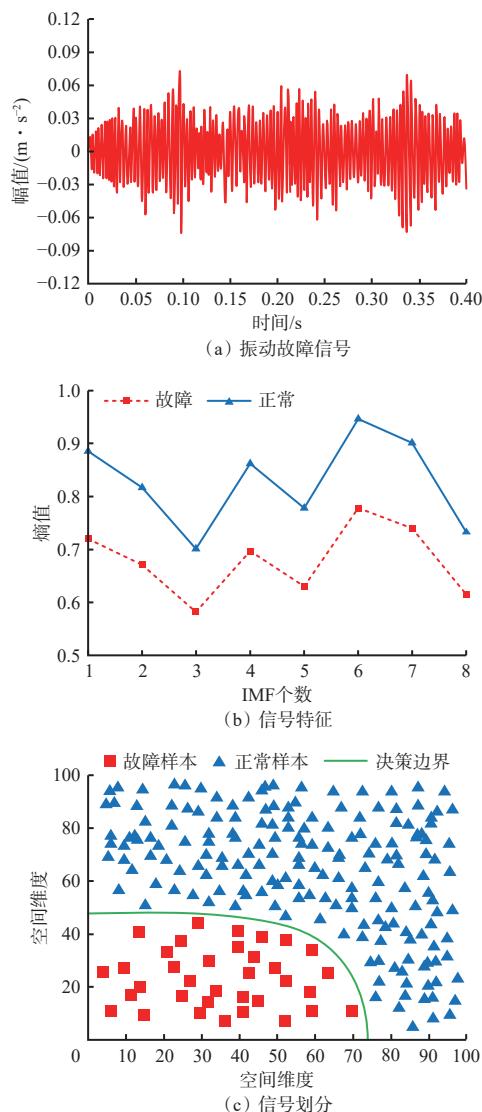


图 2 基于 OCSVM 的电气设备信号划分结果

Fig. 2 Signal classification results of electrical equipment based on OCSVM

动故障信号具有明显的动态特性和复杂性。这种复杂的波动特征为后续信号特征提取和故障检测提供了重要依据。由图 2(b)可看出, 正常样本的信号特征曲线相对平稳, 呈现出一定的规律性, 波动范围较小。而故障样本的信号特征曲线波动较为剧烈, 整体趋势不如正常样本稳定, 且在某些时刻出现明显的峰值和谷值变化。说明正常样本与故障样本在信号特征上存在显著差异, 这为利用 OCSVM 进行样本分类提供了有效的特征基础。由图 2(c)可看出, 正常样本和故障样本在空间中呈现出一定的分布规律, 通过多项式核函数的非线性映射能力, OCSVM 寻找到了一个合适的曲面型决策边界, 将正常样本和故障样本有效地划分开来。这表明所提方法通过构造防爆电气设备信号特征, 以其为寻优后 OCSVM 核函数的决策边界学习目标, 能够精准地在高维空

间中利用最优决策边界完成正常样本与故障样本的类别划分,从而有效地自动检测出隔爆型三相异步电动机中存在的振动故障。同时,也证明了多项式核函数在处理这种复杂分类问题时的有效性,它使得OCSVM能够适应信号特征的非线性关系,提高了故障检测的准确性和可靠性。

#### 2.4 振动故障自动检测性能分析

为了验证所提方法对煤矿防爆电气设备振动故障的检测准确性,将所提方法对目标防爆电气设备的振动故障检测结果与文献[4]提出的基于支持向量机和人工神经网络、文献[5]提出的基于灰狼优化和支持向量机方法作比较,结果见表2。

表2 各方法的振动故障检测准确率比较

Table 2 Comparison of the accuracy of vibration fault detection of each method

实验样本量/个	准确率/%		
	文献[4]方法	文献[5]方法	所提方法
100	89.56	84.56	98.25
200	85.78	85.12	94.23
300	79.68	85.03	95.02
400	78.26	87.21	95.25
500	78.21	79.36	94.65
600	74.51	78.25	92.35

由表2可看出,所提方法在所有样本量下的检测准确率均显著高于文献[4]和文献[5]方法。尤其是在小样本量(100个样本)下,所提方法的准确率达到了98.25%,远高于其他方法。随着样本量的增加,所提方法的准确率虽有一定变化,但整体波动幅度较小,表现出较高的稳定性。这是因为该方法能够有效处理防爆电气设备振动故障的非线性关系和高维特征,在区分正常信号与振动故障信号方面具备更强的辨识能力,进而有效避免了误检和漏检现象。

### 3 结论

1) 在验证OCSVM性能实验中,随着迭代次数递增,电气设备振动故障数量减少。迭代20次时,OCSVM能在较短时间内收敛并稳定,优化效果良好。

2) 利用OCSVM对电气设备信号划分,振动故障信号复杂、不规则,正常与故障样本信号特征差异显著。通过多项式核函数,OCSVM能在高维空间用曲面型决策边界有效划分正常与故障样本,检测振动故障准确可靠。

3) 所提方法在各样本量下振动故障检测准确率均较对比方法高,小样本量时优势明显,且随着样本

量增加,准确率波动小、稳定性高。

4) OCSVM在处理新数据时泛化能力有限,尤其是在面对未见过的故障类型时;计算复杂度较高,在大规模数据集上运行时可能影响实时性;特征选择主要依赖人工经验,缺乏自动化的特征选择机制。未来的研究将致力于引入深度学习等先进技术,提升OCSVM的学习能力和自适应能力,进一步增强模型的泛化能力;建立更完善、涵盖更多故障类型的大型数据集,为模型提供更全面的数据支持。

#### 参考文献(References):

- [1] 雷志鹏,姜宛廷,门汝佳,等.矿用三元乙丙橡胶高压电缆绝缘老化机理及状态评估技术研究进展[J].工矿自动化,2023,49(9):167-177.  
LEI Zhipeng, JIANG Wanting, MEN Rujia, et al. Research progress on insulation aging mechanism and condition evaluation technology of mining EPDM high-voltage cables[J]. Journal of Mine Automation, 2023, 49(9): 167-177.
- [2] 刘思莉,张宇,刘军.地下储气库生产站场防爆电气设备使用与管理[J].石油化工安全环保技术,2022,38(6):42-44, 7.  
LIU Sili, ZHANG Yu, LIU Jun. Use and management of explosion-proof electrical equipment in production sites of underground gas storage[J]. Petrochemical Safety and Environmental Protection Technology, 2022, 38(6): 42-44, 7.
- [3] 罗振敏,王晓悦,丁旭涵,等.碳氢-生物表面活性剂在电解质加载下的降尘及防爆性能研究[J].中国安全生产科学技术,2023,19(增刊2):166-173.  
LUO Zhenmin, WANG Xiaoyue, DING Xuhuan, et al. Study on dust reduction and explosion-proof performance of hydrocarbon-bio surfactants under electrolyte loading[J]. Journal of Safety Science and Technology, 2023, 19(S2): 166-173.
- [4] LAIB DIT LEKSIR Y, GUERFI K, AMOURI A, et al. Detection of electrical fault in medium voltage installation using support vector machine and artificial neural network[J]. Russian Journal of Nondestructive Testing, 2022, 58(3):176-185.
- [5] ZOU Xin, LYU Rongxin, LI Xinyan, et al. Intelligent electrical fault detection and recognition based on gray wolf optimization and support vector machine[J]. Journal of Physics: Conference Series, 2022, 2181(1). DOI: 10.1088/1742-6596/2181/1/012058.
- [6] SHI Wenyun, REN Xiaoming. Electrical fault detection equipment based on infrared image fusion[J]. Procedia Computer Science, 2022, 208: 509-515.
- [7] CHELLAMUTHU S, SEKARAN E C, ANNAMALAI S, et al. Fault detection in electrical equipment by infrared thermography images using spiking neural network through hybrid feature selection[J]. Journal of

Circuits, Systems and Computers, 2022, 32(8) . DOI: 10.1142/S0218126623501396.

[8] 刘赫, 赵天成, 刘俊博, 等. 基于深度残差 UNet 网络的电气设备红外图像分割方法[J]. 红外技术, 2022, 44(12): 1351-1357.

LIU He, ZHAO Tiancheng, LIU Junbo, et al. Deep residual UNet network-based infrared image segmentation method for electrical equipment[J]. Infrared Technology, 2022, 44(12): 1351-1357.

[9] 邓军, 王志强, 王伟峰, 等. 基于 LSTM-AE-OCSVM 的带式输送机火灾监测隐患识别技术[J]. 煤炭技术, 2023, 42(1): 225-229.

DENG Jun, WANG Zhiqiang, WANG Weifeng, et al. Hidden danger identification technology of belt conveyor fire monitoring based on LSTM-AE-OCSVM[J]. Coal Technology, 2023, 42(1): 225-229.

[10] 黄宇斐, 石新发, 贺石中, 等. 一种基于主成分分析与支持向量机的风电齿轮箱故障诊断方法[J]. 热能动力工程, 2022, 37(10): 175-181.

HUANG Yufei, SHI Xinfu, HE Shizhong, et al. A fault diagnosis method of wind turbine gearbox based on PCA and SVM[J]. Journal of Engineering for Thermal Energy and Power, 2022, 37(10): 175-181.

[11] 闫汇聪, 刘德山, 陈浪, 等. 散度核协同表示与空谱融合特征的高光谱图像分类算法[J]. 计算机应用与软件, 2023, 40(2): 287-295.

YAN Huicong, LIU Deshan, CHEN Lang, et al. A hyperspectral image classification algorithm based on divergence kernel collaborative representation and spatial-spectral fusion feature[J]. Computer Applications and Software, 2023, 40(2): 287-295.

[12] 余柏杨, 吕宏强, 周岩, 等. 基于机器学习的高速复杂流场流动控制效果预测分析[J]. 实验流体力学, 2022, 36(3): 44-54.

YU Baiyang, LYU Hongqiang, ZHOU Yan, et al. Predictive analysis of flow control in high-speed complex flow field based on machine learning[J]. Journal of Experiments in Fluid Mechanics, 2022, 36(3): 44-54.

[13] 金长宇, 于佳强, 王强, 等. 基于集成学习 CatBoost 优化模型的爆堆大块率预测[J]. 东北大学学报(自然科学版), 2023, 44(12): 1743-1750.

JIN Changyu, YU Jiaqiang, WANG Qiang, et al. Prediction of blasting fragment large block percentage ratio based on ensemble learning CatBoost model[J]. Journal of Northeastern University(Natural Science), 2023, 44(12): 1743-1750.

[14] 花靖, 蒋秀, 于超, 等. 基于改进型 SVM 算法的气液两相流持液率计算模型[J]. 西安石油大学学报(自然科学版), 2022, 37(6): 103-110, 118.

HUA Jing, JIANG Xiu, YU Chao, et al. Liquid holdup calculation model of gas-liquid two-phase flow based on improved SVM algorithm[J]. Journal of Xi'an Shiyou University(Natural Science Edition), 2022, 37(6): 103-110, 118.

[15] 荣统瑞, 侯恩科, 夏冰冰. 基于二次分解和 BO-BiLSTM 组合模型的采煤工作面瓦斯涌出量预测方法研究[J]. 煤矿安全, 2024, 55(5): 83-92.

RONG Tongrui, HOU Enke, XIA Bingbing. Research on prediction method of coal mining face gas outflow based on quadratic decomposition and BO-BiLSTM combination model[J]. Safety in Coal Mines, 2024, 55(5): 83-92.

[16] 师素珍, 石贵飞, 刘最亮, 等. 基于多变量 LSTM 网络的 K2 灰岩富水区预测——以阳泉泊里矿区为例[J]. 煤田地质与勘探, 2023, 51(5): 155-163.

SHI Suzhen, SHI Guifei, LIU Zuiliang, et al. Predicting the water-yield properties of K2 limestones based on multivariate LSTM neural network: a case study of the Poli Mining Area in Yangquan[J]. Coal Geology & Exploration, 2023, 51(5): 155-163.

[17] 代鑫, 胡斌, 李京, 等. 炭质泥页岩剪切破坏声发射特性及其分形特征[J]. 科学技术与工程, 2024, 24(12): 4909-4915.

DAI Xin, HU Bin, LI Jing, et al. Acoustic emission of carbonaceous shale and its fractal characteristics under shear failure[J]. Science Technology and Engineering, 2024, 24(12): 4909-4915.

[18] XU Weihua, BU Qinyuan. Matrix-based incremental feature selection method using weight-partitioned multigranulation rough set[J]. Information Sciences, 2024, 681. DOI: 10.1016/j.ins.2024.121219.

[19] 王静红, 田长申, 李昊康, 等. 基于拉格朗日对偶的小样本学习隐私保护和公平性约束方法[J]. 计算机科学, 2024, 51(7): 405-412.

WANG Jinghong, TIAN Changshen, LI Haokang, et al. Lagrangian dual-based privacy protection and fairness constrained method for few-shot learning[J]. Computer Science, 2024, 51(7): 405-412.

[20] 张先锋. 具终端状态约束的无穷维随机发展方程的线性二次最优控制[J]. 四川大学学报(自然科学版), 2024, 61(3): 75-80.

ZHANG Xianfeng. Linear quadratic optimal control problem for stochastic evolution equations with terminal state constraints in infinite dimensions[J]. Journal of Sichuan University(Natural Science Edition), 2024, 61(3): 75-80.

[21] 林韧昊, 周清雷, 嵇天卿, 等. 基于决策边界分析的深度神经网络鲁棒性评估与优先次序验证[J]. 计算机学报, 2024, 47(4): 862-876.

LIN Renhao, ZHOU Qinglei, HU Tianqing, et al. Robustness evaluation and prioritization verification for deep neural networks via decision boundary analysis[J]. Chinese Journal of Computers, 2024, 47(4): 862-876.