

基于BO优化SVM轴承故障的静电信号识别方法<sup>\*</sup>吴江平<sup>1</sup> 刘若晨<sup>1</sup> 孙见忠<sup>2</sup> 左洪福<sup>2</sup> 张兰春<sup>1</sup>

(1.江苏理工学院汽车与交通工程学院 常州 213001; 2.南京航空航天大学民航学院 南京 211106)

**摘要:** 针对新型静电监测技术应用于滚动轴承故障诊断时,静电信号易受干扰、故障识别率偏低的问题,提出了一种基于贝叶斯优化(BO)与支持向量机(SVM)相结合的滚动轴承故障静电信号识别方法。首先,通过搭建的静电仿真试验平台,采集轴承高速下不同磨损状态的静电信号,根据时域特征参数选取不同工况下的特征集;再对该模型最小误差的超参数进行选取,达到完成诊断模型训练的效果,用训练后混淆矩阵结果来评估各个模型的诊断精度。研究表明,本方法对静电监测下不同故障特征的轴承均具有一定识别能力,贝叶斯优化算法可以有效提高识别效率,其平均识别准确率可达98.82%。

**关键词:** 滚动轴承;故障识别;静电监测;支持向量机;贝叶斯优化

**中图分类号:** TH133.33;TN911.7 **文献标识码:** A **国家标准学科分类代码:** 460.4020

Fault electrostatic recognition for bearings via SVM  
optimized by Bayesian optimizationWu Jiangping<sup>1</sup> Liu Ruochen<sup>1</sup> Sun Jianzhong<sup>2</sup> Zuo Hongfu<sup>2</sup> Zhang Lanchun<sup>1</sup>

(1. School of Automobile and Traffic Engineering, Jiangsu University of Technology, Changzhou 213001, China;

2. College of Civil Aviation, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China)

**Abstract:** Aiming at the problem of easy interference of electrostatic signal and low fault recognition rate when the new electrostatic monitoring technology is applied to rolling bearing fault diagnosis, a method of electrostatic signal recognition of rolling bearing fault based on the combination of Bayesian optimization SVM is proposed. First of all, through the electrostatic simulation test platform constructed, the electrostatic signals of different wear states high speed are collected, and the feature sets of different working conditions are selected according to the time-domain feature parameters; and then the hyper-parameters of the minimum error of SVM are selected using Bayesian optimization to achieve the effect of completing the diagnostic model training, and the diagnostic accuracy of the models is evaluated with the results of the confusion matrix after training. The research results show that this method has certain recognition ability for bearings with different fault characteristics under electrostatic monitoring, and the Bayesian optimization algorithm can effectively improve the recognition efficiency, and its average recognition accuracy can reach 98.82%.

**Keywords:** rolling bearings; fault recognition; electrostatic monitoring; support vector machine; Bayesian optimization

## 0 引言

滚动轴承是机械传动设备中必不可少的零部件之一,因此一旦发生故障,将造成巨大的经济损失<sup>[1-2]</sup>。为避免轴承提前失效而产生的重要损失的问题,对滚动轴承状态进行实时监测并有效识别故障有着重要意义。相比于传统振动监测容易受工况环境影响,静电监测方法具有非接触式的特点且对早期性能退化敏感,因此具有更为广泛的使用前景<sup>[3]</sup>。

静电监测技术主要被应用于航空发动机气路系统故障所产生的静电脉冲监测中。Craig等<sup>[4]</sup>经过深入研究,验证了静电监测在润滑油路和磨损区域监测中的实际可行性。张营<sup>[5]</sup>也借助销盘磨损试验台,对轴承钢早期胶合故障的静电在线监测进行了研究,进一步证实了静电监测作为非接触性感应探测手段的可靠性与有效性。在滚动轴承故障评估方面,常用方法有模糊C均值(fuzzy C-means algorithm, FCMA)<sup>[6]</sup>、支持向量机(support vector

收稿日期:2024-07-30

<sup>\*</sup> 基金项目:国家自然科学基金(51705221, U2233204, 52072176)、江苏理工学院研究生实践创新计划项目(XSJX23\_71)资助

machine, SVM)<sup>[7]</sup>、K-medoids 聚类<sup>[8]</sup>;在特征识别方面, SVM 分类器适用维数高且样本数量少的分类问题,王贡献等<sup>[9]</sup>采用灰狼算法对 SVM 的分类参数进行了优化,针对滚动轴承振动监测下的不同故障状态进行了识别。李红月等<sup>[10]</sup>提出基于改进天鹰优化算法优化 SVM 分类模型,实现了对滚动轴承故障诊断准确率达 98%。焦静等<sup>[11]</sup>通过基于一种数字调制方法(minimum shift keying, MSK)优化 SVM 滚动轴承分类方法分别完成对轴承的故障数据集及全寿命周期数据集的校验对比,有效提高了分类准确率。因此,在优化 SVM 模型时,参数调优至关重要。传统方法如网格搜索(grid search, GS)和遗传算法(genetic algorithm, GA)存在耗时长、易陷入局部最优的缺点,而随机搜索、贝叶斯优化(Bayesian optimization, BO)等针对非突出问题时更高效、准确率更高。又由于上述方法主要针对振动监测信号采集,而针对静电监测下采集的信号故障研究较少,刘舒沁等<sup>[12-13]</sup>针对滚动轴承在常规监测方法下耦合多激励源问题,引入静电监测技术,相比于振动检测,静电检测采集的信号源能较为直接的反映轴承故障信息,为设备故障诊断提供了新思路。

针对以上问题,为进一步实现滚动轴承的静电智能监测,提出了一种基于贝叶斯优化的 SVM 轴承故障静电信号识别的模型,为轴承的健康管理和维护提供新方法,以不同磨损下轴承的静电数据为训练对象,构建特征集,通过改进后的 SVM 模型,实现滚动轴承磨损故障的识别分类目的。通过与不同算法比较得出结论,该方法具有一定优势,从而为静电监测技术的实际应用提供参考。

## 1 静电监测原理及算法基础

### 1.1 静电监测原理

当静电传感器靠近轴承磨损区时,摩擦产生的电荷被吸引至探极。正电子运动产生静电感应,导致探极内电子聚集或远离。感应电荷不易直接探测,需通过信号调节单元转化为静电感应电压信号,用于测量和研究。这是静电监测的基本原理<sup>[14-15]</sup>,如图 1 所示。

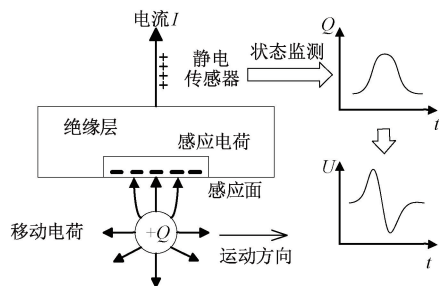


图 1 静电监测原理

Fig. 1 Principle of static electricity monitoring

在对滚动轴承磨损区域进行感应电荷监测时,将静电传感器的感应面感应电荷量为  $Q(T)$ ,采集系统显示的电

压信号记为  $U(T)$ ,默认系统初始状态为 0。经拉普拉斯变换后的电荷量  $Q(T)$ 与电压量  $U(T)$ 分别为  $Q(S)$ 、 $U(S)$ ,二者满足的关系式为:

$$U(S) = \frac{R \cdot S \cdot Q(S)}{R \cdot C \cdot S + 1} \quad (1)$$

其中,  $R$  为等效电阻值;  $S$  为  $T$  时刻对应的频率;  $C$  为电容值。当时,静电信号监测模型可等效为:

$$U(T) = R \frac{dQ}{dT} \quad (2)$$

因此,轴承采集系统采集到的原始电压信号  $U(T)$ 和静电传感器感应面电荷量  $Q(T)$ 的一阶导数成正比,表明采集到的静电电压变化对滚动轴承的磨损程度有直观的反应。

### 1.2 SVM 模型

SVM 是依据统计学理论构建的机器学习算法。SVM 模型原理是寻求代表性的支持向量机来代替全局样本量,依据支持向量进行分类实现对位置样本区分<sup>[16]</sup>。线性 SVM 分类模型如下:

$$f(x) = \text{sign}(\sum_{i=1}^n \alpha_i y_i x_i^T x + b) \quad (3)$$

如果样本不能完全符合约束条件  $y_i(\omega^T x_i + b) \geq 1$ ,为使 SVM 提高适用范围,可以增加间隔条件,允许存在一定样本量不满足上述约束条件。在 SVM 分类过程中增加一个约束,如式(4)所示,同时,增加了惩罚项  $C$  来保证不满足约束条件的样本量最小化,如式(5)所示。

$$y_i(\omega^T x_i + b) + \xi_i \geq 1 \quad (4)$$

$$\min_{\omega, b} (\frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^j \xi_i) \quad (5)$$

式中:  $C$  为惩罚因子常数,  $j$  为样本错误分类量。

针对非线性分类,引入核函数的概念,将样本从低维映射到高维空间进行分类处理,成功将线性 SVM 模型扩充至非线性 SVM 模型。而根据 Mercer 条件,其非线性核函数需要满足:任意半正定函数能作为核函数。

SVM 在做分类预测时展现了一种清晰且基于数学原理的决策过程。

SVM 的决策机理如下:

1) 对数据进行清洗,特征提取以及特征缩放,即对数据进行标准化或归一化处理,以消除不同特征之间量纲的影响。

2) 构建特征空间,对于线性不可分的数据,通过引入核函数将数据映射到高维特征空间中,使其在高维空间中变得线性可分。

3) 寻找最优超平面,这也是 SVM 的核心思想。在特征空间中, SVM 的目标是找到一个超平面,使得不同类别的样本之间的间隔最大化,能够有效地将不同类别的样本分开,提高模型的泛化能力,使得模型对于未知数据的分类更加准确。

4)确定支持向量,通过求解,将确定距离超平面最近的样本点,这些点也直接决定了超平面的边界,也称为支持向量。

5)分类决策,将需要分类的新样本输入到已经训练好的 SVM 模型中,计算新样本到最优超平面的距离,根据新样本到超平面的距离的符号来判断其类别,从而实现分类。

### 1.3 贝叶斯优化改进 SVM

在 SVM 训练过程中,针对不同的 SVM 特性,需要选定不同 SVM 模型的核函数、惩罚因子和核函数约束参数。这些超参数的选取会影响整个 SVM 的分类能力,需要采取合适的优化算法进行判定验证。贝叶斯优化是一种自适应调节的超参数寻优算法,适用于数据分类、回归预测模型等场景。概率代理模型和采集函数是贝叶斯优化算法的两个核心组件<sup>[17]</sup>。用于优化的 SVM 参数组合,其中过程如下:

$$f(x) \sim GP[m(x), k(x, x')] \quad (6)$$

式中:  $m(x) = E(f(x))$  为均值函数代表样本  $f(x)$  的数学期望;

$k(x, x') = E\{[f(x) - m(x)][f(x') - m(x')]\}$  为协方差函数。

其中优化过程基于被检索的点来预测不同点目标函数的均值和方差,然后利用其均值和方差来建立目标的采集函数,用以确定在下次迭代中的目标采集点位置,结合使用 K 折交叉验证法进一步提高模型评估的准确度。K 折交叉方法的核心思想是将原本静电数据集随机进行挑选划分为  $K$  个相互独立的数据子集,单独将一个子集当作测试集,剩余  $K-1$  个子集作为训练集来训练模型,可以充分利用数据集进行模型训练和评估,提高模型的泛化能力。然后,将  $K-1$  个训练集当作总数据集再进行  $K$  个子集的测试集、训练集划分。每次划分定义的测试集互不相同,重复  $K$  次求得  $K$  次模型结果的平均,达到减少模型误差效果。

贝叶斯优化算法的过程如下:

1)从模型惩罚因子  $C$  和核函数约束  $\gamma$  的设定检索范围内随机确定  $n_0$  个初始采集点,然后利用  $K$  折交叉验证得出各个采集点其平均准确率来当作目标函数  $f$  的大小,再通过这些初始采集点及其对应的目标函数值大小,构建一个高斯过程(Gaussian Process)代理模型,以近似目标函数  $f$  的值分布,将初始的采集点及其目标函数值都存在采集点的集合  $M$  中;

2)通过贝叶斯优化算法中的采集函数,从检索范围内重新确定一个新的采集点  $x_i$ ,这个采集函数基于当前代理模型的后验分布,旨在找到最有可能提升目标函数值或提供最大信息增益的点,即  $f(x_i)$ ;

3)将  $x_i$  和  $f(x_i)$  加入到集合  $M$  中,再通过新的数据集重新训练更新模型,以提高其对目标函数真实分布的拟合度;

4)确定模型最大的迭代次数作为该优化算法的结束标

准,即迭代次数达到设定的次数,就会停止算法,并输出相应的最优值。

## 2 故障诊断模型

基于贝叶斯优化的 SVM 模型的流程图,如图 2 所示。

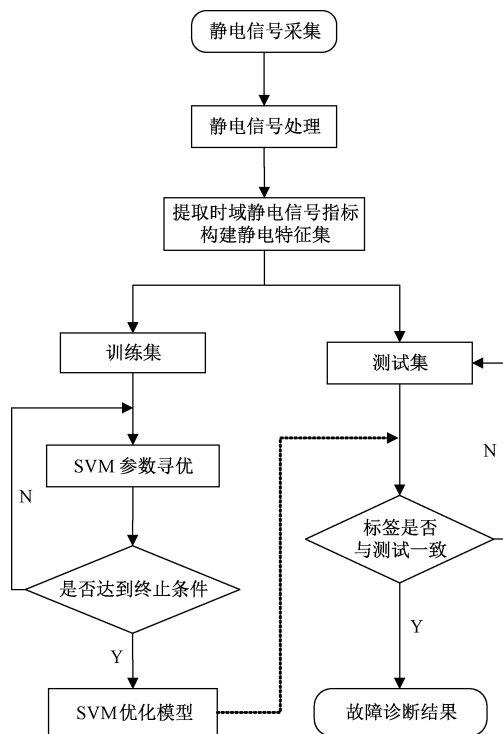


图 2 基于贝叶斯优化 SVM 故障诊断模型

Fig. 2 SVM fault diagnosis model based on Bayesian optimization

针对滚动轴承故障数据的诊断具体步骤如下:

1)静电信号采集与预处理:通过静电监测实验平台,采集滚动轴承的故障静电信号,并使用滤波器对原始信号去除工频干扰,得到高信噪比的静电信号。

2)构建静电信号特征集:从静电信号中提取时域频域特征参数,包括均方根值(root mean square,RMS)、峰峰值(peak-to-peak,PP)、标准偏差频率和频率中心参数共同组成时频域特征集。

3)超参数优化:使用贝叶斯优化惩罚因子和核函数约束参数,估计最优模型的泛化误差,寻找估算精度最高时的超参数,即最优值。

4)训练 SVM 模型:将静电时域特征集作为输入,与之对应的标签作为输出,以此训练改进的 SVM 模型,得到故障诊断模型。

5)故障识别:将预备好的测试集导入训练完成的分类 SVM 模型中进行轴承故障识别。

## 3 实验分析

### 3.1 实验平台及流程

为验证基于静电特征的滚动轴承故障识别算法的性



能,仿真实验搭建了针对磨损轴承实验件的静电监测实验平台。由电机、轴承试验件、静电传感器、信号电路、总装实验控制台以及 Labview 监测系统构成的自制实验平台,实现对滚动轴承磨损状态的静电监测。其中轴承试验件采用线切割的方式预设滚子、内圈、外圈的典型故障,即在测试轴承不同部分切一个与轴线平行的窄缝,如图 3 所示。




图 3 轴承试验件  
Fig. 3 Bearing test piece

实验平台通过控制台改变滚动轴承运行转速,由静电传感器探测摩擦副荷电状况,静电传感器需要尽可能靠近滚动轴承测量区域,将移动电荷经电荷放大器放大后进行 A/D 转化,并输出至计算机端的 Labview 监测系统,整体结构如图 4 所示,其中静电传感器特别设计,包括探极感应层、绝缘层、屏蔽层及信号传输端,确保静电信号的准确捕捉与传输。




图 4 实验设备  
Fig. 4 Experimental equipment

为了尽可能全面捕捉到不同故障模式的细节,在静电信号中特征参数提取时,一方面,对信号幅值和能量波动较敏感的时域指标中带量纲的 RMS 和 PP 值参数进行提取;另一方面,又由于该时域特征参数易受载荷转速等工况变化的影响,存在不足,故结合频域特征中标准偏差频率和频率中心参数共同组成时频域特征集,如表 1 所示。

实验选用轴承型号为 SKF-6204-2Z 型深沟球轴承,将

表 1 时频域特征参数	
Table 1 Time-frequency domain characteristic parameters	
参数	公式
RMS	$x_{rms} = \sqrt{\frac{\sum_{n=1}^N (x_n)^2}{N}}$
PP	$x_{pp} = \max(x_n) - \min(x_n)$
频率中心	$x_{fc} = \frac{\sum_{k=1}^K f_k s(k)}{\sum_{k=1}^K s(k)}$
标准偏差频率	$x_{stdf} = \sqrt{\frac{\sum_{k=1}^K (f_k - x_{fc})^2 s(k)}{\sum_{k=1}^K s(k)}}$

不同故障程度和故障类型的滚动轴承依次采集了 800、1 800、2 800 和 3 800 RPM 时的静电信号,在各工况数据下取 300 个连续采样值为一组计算该组时域指标,每种工况分别为连续 80 组时域参数指标,如图 5 所示,其中 Li、Me、He 工况分别对应轻度、中度和重度工况。在图 5(a)中每一个特征值代表了对应故障轴承连续 300 个采样点的均方根值(RMS),而每 80 组 RMS 值又反应了一种转速下的静电水平变化情况。

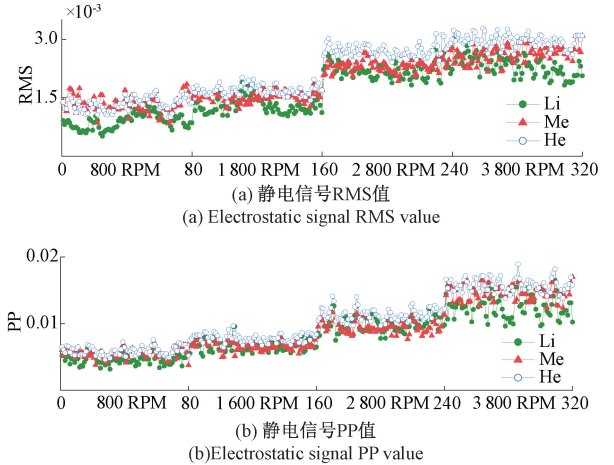


图 5 不同故障下时域特征图  
Fig. 5 Time-domain characteristic map under different faults

在 4 个转速阶段下,RMS 和 PP 值都有着明显的区分程度,提升轴承故障程度后,静电水平也发生规律性提升;尤其是在轴承 3 800 RPM 的高速工况下,其波动相比之前显著加剧。一方面,可能是部分带电粒子受转速工况影响大,静电水平极值会存在较大落差。另一方面,运动带电粒子被探极面吸附达到稳定状态需要一定时间,所以幅值波动明显。说明了时域特征 RMS 和 PP 值对于变工况下轴

承静电水平差异有敏锐的感知,与转速大小成正相关性,高转速可以较好反应轴承工况变化下的静电变化。

在 3 800 RPM 高速下,不同故障类型的轴承静电 RMS 值都有较大的提升,因此,轴承高速下静电水平提升最明显,易于对故障进行监测。

根据对以上静电信号分析,将实验参数设置的轴承转速为 3 800 RPM,采样频率为 12 kHz,每组采集时间 10 s。为了提高模型的泛化能力和适用性,图 4 所搭建的静电实验平台分别对轴承试验件根据不同故障类型、不同故障程度以及转速载荷区别,确定 7 种工况下轴承静电信号的采集,并编号 A-G,如表 2 所示。

表 2 7 组轴承工况类别

Table 2 7 groups of bearings working condition category

编号	故障类型	故障程度	转速/ RPM	载荷/ (N·m)
A	滚子	轻	3 800	0
B	滚子	重	3 800	0
C	内圈	轻	3 800	0
D	内圈	轻	1 800	0
E	外圈	轻	3 800	0
F	外圈	轻	3 800	3
G	正常	无	3 800	0

单组工况都包含了两种相近运行工况的对比(如编号 A:滚子故障-重度-3 800 RPM-0 N·m 负载和编号 B:滚子故障-轻度-3 800 RPM-0 N·m 负载)。根据时频域特征参数 RMS、PP、标准偏差频率和频率中心来提取指标。每一组静电信号特征集是由对应工况轴承连续 125 000 个采样点提取而得,对各工况静电水平变化具有普适性,并在每种工况下选取 240 个样本作为训练集,然后在剩余数据中选择 120 个样本作为测试集。

3.2 静电信号预处理

在轴承故障信号采集中,工频干扰是采集过程中占比较大的噪声源,信号处理中常采用设置合理的滤波器进行工频去噪,在频率为 50 Hz 可见的波形中,附着了静电特征信号的局部振荡波动,而利用数字滤波器对工频干扰进行滤除后,可以得到振荡较为规律的轴承磨损区静电特征信号。

由时域特征分析可知,故障滚动轴承在高速运转下产生的静电感应现象更明显。为了研究滚动轴承不同故障类型静电特性,采集不同故障类型不同状态下的静电信号,如图 6 所示。其中,图 6 分别对应滚子故障、内圈故障、外圈故障和正常轴承 0.2 s 的静电信号。由时域信号表明,同转速下轴承存在不同位置故障时,磨损区域的静电感应幅值大小相近,但波形表现不同。而对正常滚动轴承进行静电监测时,产生的信号幅值小、波动弱。

3.3 实验结果分析

使用贝叶斯优化惩罚因子和核函数的约束参数,针对




图 6 静电监测时域信号

Fig. 6 Electrostatic monitoring time domain signal

生成静电轴承数据训练集进行模型预测,贝叶斯优化来估计各超参数下 SVM 模型的泛化误差。

实际贝叶斯优化的时长为 304.41 s,以下为优化过程图,如图 7 所示。随着迭代优化,模型最小分类误差值变小。当优化迭代到第 16 步时,估计最小分类误差和观测到最小分类误差同时达到最小值为 0.167 9。所以,选取第 16 次迭代优化的超参数值预设 SVM 模型,即当惩罚因子和核函数约束值分别取 15.686 2 和 0.1 时,改进的 SVM




图 7 模型超参数优化过程

Fig. 7 Model hyperparameter optimization process

模型会达到最优分类效果。

为了验证本方法在滚动轴承静电识别的性能和优势，本文选用常见的分类模型，有决策树、KNN、GS-SVM 以及 BO-SVM 模型分别进行静电数据集训练预测。通过这一系列模型的训练与测试，旨在对比各模型在静电监测下的轴承故障识别上的性能差异。故障诊断结果使用分类混淆矩阵来表示，如图 8 所示。




图 8 分类模型的混淆矩阵

Fig. 8 Confusion matrix for classification model

根据混淆矩阵可以直观看出不同分类模型的识别准确度，其中纵坐标为 A~G 工况下轴承数据的真实标签，横坐标表示分类模型给出的预测标签。

图 8(a)表明决策树分类模型对 B 和 F 工况静电数据预测较差，其中 B 工况仅 81 个数据点成功判别为 B 工况下静电特征数据，而 F 工况则只有 74 个数据特征被成功预测，但从图中可知其他工况下仍有 90% 以上的识别准确率。

图 8(d)表明 BO-SVM 分类模型准确率最高，基本可以准确识别，只有对轴承滚子的识别中存在的识别错误，但还是比图 8(c)中的 GS-SVM 模型的识别准确率提高了一些，与其他两种方法比较，其准确率则有较大的提升，从中就发现 GS 算法寻优的 SVM 模型有可能是局部最优的，其模型有点过拟合的趋势，使得其表现不佳。

为了正确判断各模型性能，确保试验最后结果的精确性，对上述 4 种分类方法进行 20 次重复的分析比较。将 4 种分类模型混淆矩阵计算出各模型的最高分类精确度、最低分类准确度以及平均分类准确度，如表 3 所示。其中，决策树和 KNN 模型的平均分类准确度在 95% 以下，而经过不同优化过后的 SVM 模型分类准确度要超过 95%，其中 BO-SVM 分类模型的精度最高，有 98.82%，主要是因为 BO 算法能快速定位 SVM 的全局最优参数，通过采集函数，在未知区域与已知较优值的区域间做出相应权衡，来选择下一评估点；同时减少了模型对于无效区域的搜索工作，明确了目标函数所在分布，实现了优化的高效与精准。

为了展现贝叶斯优化的 SVM 模型对于静电信号特征的分类效果，可以从特征集的分类正确散点分布图来观察，如图 9 所示。从图中可以发现，A~G 7 种工况的特征点相对分散，表明轴承在这 7 种工况下的数据特征点容易被划分，这也印证了分类模型混淆矩阵中预测正确的数据点占





表 3 不同模型结果

Table 3 Results of different models %

分类模型	最低准确率	最高准确率	平均准确率
决策树	78.15	90.94	84.86
KNN	83.68	92.53	88.34
GS-SVM	92.88	96.06	94.87
BO-SVM	98.01	99.36	98.82




图 9 分类正确散点分布图

Fig. 9 Scatterplot of correct classification

绝大多数的现象。其中正常工况下的静电数据特征与其他各组工况相比较下,整体分布相对分散,更容易被预测,这也与混淆矩阵中 G 工况被成功预测的准确率相符合。

4 结 论

针对静电信号传统故障特征识别算法复杂,人为干预强的问题,采用改进支持向量机模型对静电时域特征集进行训练分类,提出了一种贝叶斯优化的 SVM 智能故障识别方法,实验结果表明:新型静电监测对滚动轴承故障类型能进行有效识别,为后续故障分类的准确性打下了基础;该模型在基于代理模型和采集函数的迭代优化过程,在有限的评估次数内有效地逼近最优的超参数设置,可以在各工况下提高一定的识别效果;对于滚动轴承在静电监测下该优化模型准确率达 98.82%,具有应用价值。

参考文献

[1] LUO M, LI CH SH, ZHANG X Y, et al. Compound feature selection and parameter optimization of ELM for fault diagnosis of rolling element bearings[J]. ISA Transactions, 2016, 65: 556-566.

[2] 杨旭, 张涛, 李玉梅, 等. ISSA 优化 SVM 的电机滚动轴承故障诊断[J]. 电子测量技术, 2023, 46(15): 186-192.

YANG X, ZHANG T, LI Y M, et al. ISSA optimized SVM for rolling bearing fault diagnosis in electric

machines[J]. Electronic Measurement Technology, 2023, 46(15): 186-192.

[3] SHAO H D, JIANG H K, LIN Y, et al. A novel method for intelligent fault diagnosis of rolling bearings using ensemble deep auto-encoders [J]. Mechanical Systems and Signal Processing, 2018, 102: 278-297.

[4] CRAIG M, HARVEY T J, WOOD R J K, et al. Advanced condition monitoring of tapered roller bearings, Part 1[J]. Tribology International, 2009, 42(11): 1846-1856.

[5] 张营. 滚动轴承磨损区域静电监测技术及寿命预测方法研究[D]. 南京:南京航空航天大学民航学院, 2013: 2-10.

ZHANG Y. Research on electrostatic monitoring technology and life prediction method for rolling bearing wear region[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, College of Civil Aviation, 2013: 2-10.

[6] WANG B, HU X, LI H R. Rolling bearing performance degradation condition recognition based on mathematical morphological fractal dimension and fuzzy C-means[J]. Measurement, 2017, 109: 1-8.

[7] KHAN M A A, KHANAM S. Feature-based performance of SVM and KNN classifiers for diagnosis of rolling element bearing faults[J]. Vibroengineering Procedia, 2021, 39: 36-42.

[8] AKHAND R, UPADHYAY S H. Bearing performance degradation assessment based on a combination of empirical mode decomposition and K-medoids clustering[J]. Mechanical Systems and Signal Processing, 2017, 93: 16-29.

[9] 王贡献, 张森, 胡志辉, 等. 基于多尺度均值排列熵和参数优化支持向量机的轴承故障诊断[J]. 振动与冲击, 2022, 41(1): 221-228.

WANG G X, ZHANG M, HU ZH H, et al. Bearing fault diagnosis based on multi-scale mean-aligned entropy and parameter-optimized support vector machine[J]. Vibration and Shock, 2022, 41(1): 221-228.

[10] 李红月, 高英杰, 朱文昌. IAO 优化 SVM 的电机滚动轴承故障诊断[J]. 电子测量技术, 2022, 45(10): 126-132.

LI H Y, GAO Y J, ZHU W CH. IAO optimized SVM for motor rolling bearing fault diagnosis[J]. Electronic Measurement Technology, 2022, 45(10): 126-132.

[11] 焦静, 岳建海, 裴迪. 基于 MSK-SVM 的滚动轴承故障诊断方法[J]. 电子测量与仪器学报, 2022, 36(1): 109-117.



JIAO J, YUE J H, PEI D. A rolling bearing fault diagnosis method based on MSK-SVM[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(1): 109-117.

[12] 刘舒沁, 刘若晨, 王益民, 等. 基于变分模态分解的静电监测信号去噪方法研究[J]. 噪声与振动控制, 2022, 42(1): 119-124.

LIU SH Q, LIU R CH, WANG Y M, et al. Denoising method for electrostatic monitoring signals based on variational modal decomposition[J]. Noise and Vibration Control, 2022, 42(1): 119-124.

[13] 刘若晨, 左洪福, 冒慧杰, 等. 润滑油路静电传感器动态特性仿真与试验[J]. 航空动力学报, 2017, 32(10): 2438-2446.

LIU R CH, ZUO H F, MAO H J, et al. Simulation and test of dynamic characteristics of lubricating oil path electrostatic sensor[J]. Journal of Aerospace Dynamics, 2017, 32(10): 2438-2446.

[14] 顾双双, 刘若晨, 严旭, 等. 基于磨损区域静电监测的滚动轴承故障信号特征分析[J]. 中国测试, 2024, 50(5): 145-152.

GU SH SH, LIU R CH, YAN X, et al. Characterization of rolling bearing fault signals based on electrostatic monitoring of wear areas[J]. China Testing, 2024, 50(5): 145-152.

[15] YIN Y B, ZUO H F, MAO H J, et al. Experimental investigation on electrostatic monitoring technology for civil turbofan engine[J]. Journal of Vibroengineering, 2017, 19(2): 967-987.

[16] SONG X M, WEI W H, ZHOU J B, et al. Bayesian optimized hybrid kernel SVM for rolling bearing fault diagnosis[J]. Sensors, 2023, 23(11): 5137.

[17] 冯瑞杰, 陈争光, 衣淑娟. 基于贝叶斯优化的 SVM 玉米品种鉴别研究[J]. 光谱学与光谱分析, 2022, 42(6): 1698-1703.

FENG R J, CHEN ZH G, YI SH J. Study on identification of SVM maize varieties based on Bayesian optimization[J]. Spectroscopy and Spectral Analysis, 2022, 42(6): 1698-1703.

作者简介

吴江平, 硕士研究生, 主要研究方向为轴承状态监测及智能诊断研究。

E-mail: wujiangping\_1213@163.com

刘若晨(通信作者), 博士, 副教授, 硕士生导师, 主要研究方向为智能传感技术、寿命预测与健康管理。

E-mail: liuruochen\_nuaa@163.com