

DOI:10.3969/j.issn.1001-4551.2023.11.001

基于优化核函数带宽 SVDD 的机械振动预警模型*

刘晓金¹, 陈文武^{1*}, 王庆锋²

(1. 中石化安全工程研究院有限公司 设备安全研究室, 山东 青岛 266000;

2. 北京化工大学 高端机械设备健康监控及自愈化北京市重点实验室, 北京 100029)

摘要: 基于高斯核函数的支持向量数据描述(SVDD), 因其具有良好的异常检测性能, 常被用于机械振动故障预警领域, 但其性能的好坏受限于核函数带宽的取值是否适宜。为此, 针对常规高斯核函数支持向量数据描述(SVDD)存在需要负类样本训练模型、计算量大、不收敛、不适用于小数值数据等问题, 提出了一种不需要专家经验知识和负类样本训练 SVDD 超球体的优化核函数带宽计算方法, 构建了基于优化 SVDD 核函数带宽的机械振动故障预警模型。首先, 根据空间矩阵复杂度的信息熵, 量化表征核函数带宽的取值对 SVDD 超球体的影响; 然后, 采用粒子群优化(PSO)算法寻找空间矩阵复杂度最大时对应的核函数带宽 σ 取值, 实现了目标函数的快速收敛目的; 综合考虑惩罚参数对 SVDD 超球体描述边界的影响, 引入惩罚参数对寻优结果进行了修正, 完成了对历史正常运行状态数据驱动的机械振动故障预警模型的构建任务; 最后, 应用辛辛那提大学智能维护中心轴承试验数据集等 6 项公开实验室数据和 4 项工程案例数据, 对上述方法的实用性和可靠性进行了验证, 并将其结果与采用常规方法所得结果进行了对比验证。研究表明: 与常规方法相比, 采用优化核函数带宽计算方法训练出的机械振动故障预警模型的合格率为 100%, 超球体描述边界拟合良好, 并且不存在不收敛的问题。

关键词: 机械设备故障预警; 高斯核函数; 支持向量数据描述; 核函数带宽; 惩罚参数; 超球体; 空间矩阵复杂度; 粒子群优化算法

中图分类号: TH133; TH113.1; TP18

文献标识码: A

文章编号: 1001-4551(2023)11-1641-15

Mechanical vibration warning model based on optimized kernel bandwidth SVDD

LIU Xiaojin¹, CHEN Wenwu¹, WANG Qingfeng²

(1. Equipment Safety Research Division, Sinopec Safety Engineering Research Institute Co. Ltd., Qingdao 266000, China;

2. Beijing Key Laboratory of Health Monitoring and Self-Recovery of High-End Machinery Equipment, Beijing University of Chemical Technology, Beijing 100029, China)

Abstract: Support vector data description (SVDD) based on Gaussian kernel function was often used in the field of mechanical vibration fault warning field, because of its excellent anomaly detection performance, however its performance was limited by the appropriate value of kernel bandwidth. Therefore, aiming at the problems of conventional Gaussian kernel support vector data description (SVDD), such as the requirement of negative class data training model, complicated calculation, non-convergence, and inapplicability to small value data, an optimal kernel bandwidth calculation method was proposed which could get rid of dependence on expert experience knowledge and negative class data to train SVDD hypersphere. A mechanical vibration fault early warning model based on optimizing SVDD kernel function bandwidth was constructed. Firstly, the influence of kernel bandwidth value on SVDD hypersphere was characterized by information entropy of spatial matrix complexity. Then, the particle swarm optimization algorithm (PSO) was used to find the value of kernel function bandwidth parameter σ when the spatial matrix complexity was maximum, and the convergence of the objective function was realized fleetly. Considering the influence of penalty parameter on the description boundary of SVDD hypersphere, the penalty parameter was introduced to correct the optimization results, and the mechanical vibration fault warning model driven by historical normal operating state data was constructed.

收稿日期: 2023-02-23

基金项目: 中国石油化工股份公司科技部项目(323031); 中石化安全工程研究院项目(Y315)

作者简介: 刘晓金(1998-), 男, 江西九江人, 硕士研究生, 主要从事设备状态监测与故障诊断方面的研究。E-mail: liuxiaojinbuct@163.com

通信联系人: 陈文武, 男, 硕士, 高级工程师。E-mail: chenww.qday@sinopec.com

Finally, the practicability and reliability of the proposed method was verified by six public laboratory data and four engineering case data, and the proposed method was compared with the conventional SVDD kernel function bandwidth calculation method. The research results show that comparing with conventional methods, the incipient fault warning model trained by the optimized kernel function bandwidth calculation method has a 100% qualification rate, the hypersphere description boundary is well fitted, and there is no problem of non-convergence.

Key words: mechanical equipment fault warning; Gaussian kernel function; support vector data description (SVDD); kernel function bandwidth; penalty parameter; hypersphere; space matrix complexity; particle swarm optimization (PSO) algorithm

0 引 言

作为一种典型的单分类算法,支持向量数据描述(SVDD)仅需正类样本即可训练出一个灵敏的异常值检测模型^{[1]45}。基于这个特点,目前,SVDD在机械设备健康管理与故障预测、化工过程安全等领域中得到了广泛的应用。

例如,LI J J 等人^[2]基于变步长果蝇优化算法与复高斯小波,提出了一种 SVDD 模型,并采用该模型对起重机恒减速制动系统的性能退化过程进行了监测。林扬等人^[3]提出了一种基于主成分分析与 SVDD 的异常工况检测方法,并采用该方法对化工过程异常工况进行了检测。王晓慧等人^[4]提出了一种基于加权深度 SVDD 检测方法,并采用该方法对工业故障进行了数据检测。庞菲菲等人^[5]使用 SVDD 剔除了方位异常值,然后将其运用于水下目标的检测,取得了一定的效果。SHI P 等人^[6]提出了一种将相对密度权重与 SVDD 相结合的离群点检测算法,并将其运用于实时的水质检测中,取得了良好的应用效果。王斐等人^[7]提出了一种基于变分模态分解(variational mode decomposition, VMD)与 SVDD 的旋转机械性能退化评估模型,该模型可以准确地识别出旋转机械的早期微弱故障。赵聪聪等人^[8]基于可拓学与 SVDD,提出了一种轴承故障性能退化评估方法,并将其运用到轴承故障性能退化评估中,取得了一定的效果。刘志远等人^[9]提出了一种基于自适应混沌粒子群优化与 SVDD 的检测方法,并对齿轮箱异常状况进行了检测。陈宇晨等人^[10]基于集合经验模态分解信息量和 K 相邻概率 SVDD,提出了一种滚动轴承故障诊断方法。周建民等人^[11]使用自回归模型,提取了旋转机械故障特征值,然后将其输入一种融合了模糊 C 均值聚类与 SVDD 的模型,以此来监测旋转机械的性能退化过程。MAO W 等人^[12]提出了一种基于自适应深度特征匹配与 SVDD 的旋转机械早期故障检测模型。YANG C 等人^[13]针对 SVDD 易受到轻微波动影响的特点,提出了一种基于增量加权 SVDD 的异常检测方法。武千惠等人^{[14]2725}提出了一种基于小波包分解与支持向量数据

描述的机械剩余寿命预测方法,并用该方法对机械设备的关键部件进行了剩余寿命预测。此外,张世醒等人^[15]针对原始 SVDD 算法没有考虑超球体之间的差异性,没有重复利用 SVDD 超球体输出信息的问题,提出了一种利用证据理论的多分类 SVDD 算法。WANG B 等人^[16]为降低输入特性对 SVDD 模型的影响,提出了一种将规范变量分析与 SVDD 相结合的方法。ZHANG L 等人^[17]为实现正常样本集的在线更新,以及提高离线数据的计算精度和效率,提出了一种改进增量支持向量数据描述的方法。ZHANG C F 等人^{[18]173}针对旋转机械微弱的早期故障容易被系统干扰和噪声覆盖的问题,在传统 SVDD 的基础上,使用正类样本和负类样本构建了鲁棒支持向量数据描述模型,并且改进了超球体半径的计算方法。CHA M 等人^[19]以目标样本到分类中心的距离为 SVDD 模型中松弛变量的权重,避免了传统 SVDD 只考虑样本点与超球体中心的距离,而未将高密度区域的数据点包含在超球体内这一缺陷。

SVDD 通常与核函数一起使用。核函数将训练数据映射到高维核空间中,从而使低维空间不可分问题在高维空间中得到解决,其中高斯核函数是目前使用最广泛的核函数。基于高斯核函数的 SVDD 模型有 2 个关键参数(惩罚参数 C 、核函数带宽 σ)需要提前确定。部分学者对 SVDD 的关键参数取值问题进行了相关研究。TAX 等人^[20-21]的研究结果表明,SVDD 对惩罚参数 C 不敏感。EVANGELISTA 等人^{[22]269-270}研究认为,SVDD 的性能在很大程度上取决于核函数带宽参数 σ 的选择。

上述学者的研究成果推动了 SVDD 的实际工程应用进程,但没有很好地解决核函数带宽的取值问题。例如,文献[11-13]没有说明 SVDD 关键参数核函数带宽取值问题。文献[14]2727-2728 使用粒子群优化算法(PSO)寻找到合适的核函数带宽;但该方法仅限于让 SVDD 计算出的性能退化指数更加近似于指数劣化过程。文献[3,5,7,8,16,17]依赖于先验知识,分别将核函数带宽默认设置为 0.04、500、90、2.5、1 000、0.000 3。文献[18]174 需要负类样本不断迭代优化

核函数带宽的取值。

众多学者对 σ 的取值进行了大量的研究。例如, TAX D M 等人^{[1]57-59} 建议通过最小化支持向量与样本的比率来选择最优 σ 。SHI P 和 CHA M 等人^[6,19] 使用 k 折交叉验证的方法降低模型分类错误率,以此来寻找最优 σ 。THESSLER A 等人^[23] 在降低模型误差率的同时,使模型半径接近于 1,建立了目标函数,以寻找最优 σ 。KHAZAI S 等人^[24] 提出了一种基于样本间最大距离准则的最优 σ 取值方法。WANG H 等人^[25] 使用边界紧密性选择了最佳 σ 。LIU Z 等人^{[26]24-26} 通过寻找高维核空间矩阵(简称空间矩阵)方差平方根平均比最大值的方法,以此来选择最佳 σ 。

上述研究对推动 SVDD 在工程中的应用起到了很大作用,但是也存在一些不足。比如, TAX D M、WANG B 和 THESSLER A 的方法计算量太大, KHAZAI S 等人的方法容易导致出现欠拟合问题。笔者对 TAX D M、LIU Z、SHI P 和 CHA M 等人的方法进行验证时,发现该 3 类方法在核函数带宽取值较小时,应用效果不佳。

PSO 优化算法是一种进化计算技术^[27],其灵感来源于鸟群的觅食过程:鸟群中每只小鸟各自寻找食物的同时,又将自己寻找食物过程中所获取的信息分享给鸟群,小鸟综合考虑个体所获取的信息以及从鸟群获取的信息,以此来决定下一次的搜寻方向。由于其参数少、搜索速度快、收敛性好、易于实现等优点^[28], PSO 优化算法被广泛运用于数学、深度学习、控制工程、电力、通信等领域。

综上所述,基于 SVDD 的机械设备健康管理及故障预测技术应用广泛,针对其核函数带宽取值难以确定的问题,笔者研究核函数带宽取值对空间矩阵复杂度的影响,将高斯核函数带宽 σ 与空间矩阵复杂度(通过信息熵来量化)的影响关系作为目标函数,并利用 PSO 快速计算出高斯核带宽 σ 的最优值,从而实现在无需专家经验知识、无需负类样本训练超球体的情况下,构建基于优化 SVDD 核函数带宽的机械振动故障预警模型。

1 支持向量数据描述

SVDD 是一个经典的单分类器,其主要思路是:

首先,将低维度的训练数据通过核函数映射到高维空间中;然后,在高维空间中寻找一个球心为 a ,半径为 r 的超球体,使得训练数据集的大部分正类样本尽可能地包含在超球体中,同时尽可能地将偶发的异常样本排除在超球体之外。

体积无限大的超球体会将所有的训练样本包含在内,但是也会把负类样本包含进去,故需要权衡超球体的大小以及偶发误差散点的区分情况。即一方面超球体的描述边界需要捕捉到所有正类样本,另一方面要保持超球体的体积最小。

因此,可以将上述优化问题用以下公式进行描述:

$$F(r, a) = r^2 \quad (1)$$

式中: $F(\cdot)$ 为误差函数。

为满足上述要求,需要最小化误差函数,从而尽可能地将正类样本包含在超球体内。

要实现上述目的,需要满足下式的约束:

$$\|x_i - a\|^2 \leq r^2, i = 1, 2, 3, \dots, l \quad (2)$$

式中: $x_i = \{x_1, x_2, \dots, x_l\}$ 为训练数据集; l 为训练数据集中样本的个数。

由于训练数据集中不可避免地出现偶发误差散点,因此训练样本到超球体中心的距离不应该严格满足式(2)。

对于可能出现误差散点的情况,引入松弛变量 ξ_i , 对其进行惩罚,将式(2)更新如下:

$$\|x_i - a\|^2 \leq r^2 + \xi_i \quad (3)$$

引入松弛变量 ξ_i ($\xi_i \geq 0$) 后,可以允许部分误差散点在超球体之外。式(1)的误差函数不再满足要求,对其进行更新后如下所示:

$$F(r, a, \xi_i) = r^2 + C \sum_i \xi_i \quad (4)$$

式中: C 为惩罚参数; ξ_i 为松弛变量。

对式(4)通过引入惩罚参数 C 来控制松弛变量 ξ_i ,从而限制少量负类样本对超球体体积大小的影响。

利用拉格朗日乘数,将式(3)并入式(4),将上述优化问题转换为无约束优化问题,得到的目标函数如下所示:

$$L(r, a, \alpha_i, \beta_i, \xi_i) = r^2 + C \sum_i \xi_i - \sum_i \alpha_i \{r^2 + \xi_i^2 - (x_i^2 - 2ax_i + a^2)\} - \sum_i \beta_i \xi_i \quad (5)$$

式中: $\alpha_i \geq 0, \beta_i \geq 0$ 均为拉格朗日乘算子。

为求解上述优化问题, L 应相对于 R, a, ξ_i 最小化,相对于 α_i, β_i 最大化。将 L 对于 R, a, ξ_i 的偏导设置为 0,得到以下约束:

$$\begin{cases} \frac{\partial L}{\partial R} = 0: & \sum_i \alpha_i = 1 \\ \frac{\partial L}{\partial a} = 0: & a = \sum_i \alpha_i x_i \\ \frac{\partial L}{\partial \xi_i} = 0: & C - \alpha_i - \beta_i = 0 \end{cases} \quad (6)$$

由于 $\alpha_i = C - \xi_i$,且 $\alpha_i \geq 0, \beta_i \geq 0$,因此可以得出拉

格朗日乘算子 α_i 与 C 的大小关系如下所示:

$$0 \leq \alpha_i \leq C \quad (7)$$

将式(6)代入式(5)中,得到优化函数:

$$\begin{cases} \max L = \sum_i \alpha_i k(x_i, x_j) - \sum_{i,j} \alpha_i \alpha_j k(x_i, x_j) \\ \text{s. t. } 0 \leq \alpha_i \leq C, \sum_i \alpha_i = 1 \end{cases} \quad (8)$$

式中: $k(\cdot)$ 是核函数。

通过核函数能够将训练数据集从低维空间映射到高维空间中,使得训练数据能够在高维空间中找到大小适中的超球体。

笔者采用高斯核函数作为 SVDD 核函数,其表达式如下:

$$k(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{\sigma^2}\right), \sigma > 0 \quad (9)$$

训练样本与超球体的距离关系如下所示:

$$\begin{cases} \|x_i - a\|^2 < r^2 \rightarrow \alpha_i = 0, \beta_i = 0 \\ \|x_i - a\|^2 = r^2 \rightarrow 0 < \alpha_i < C, \beta_i = 0 \\ \|x_i - a\|^2 > r^2 \rightarrow \alpha_i = C, \beta_i > 0 \end{cases} \quad (10)$$

SVDD 二维空间超球体示意图如图 1 所示。

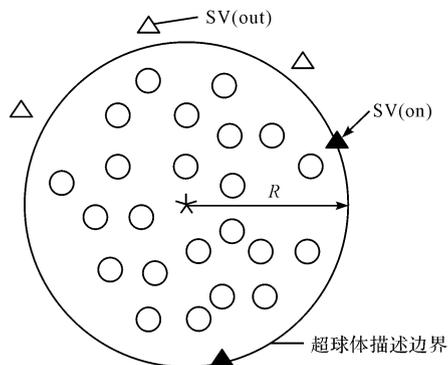


图 1 SVDD 二维空间超球体示意图

Fig.1 Schematic diagram of SVDD two-dimensional space hypersphere

由式(10)与图 1 可知:当训练样本处于超球体内, $\alpha_i = 0$,标记为 SV(in);当训练样本处于超球体的描述边界上, $0 < \alpha_i < C$,标记为 SV(on);当训练样本处于超球体描述边界之外, $\alpha_i = C$,标记为 SV(out)。在超球体描述边界上和描述边界之外的训练样本均为支持向量(SVs)。

超球体的广义半径 r 可由在超球体描述边界上的支持向量到超球体中心 a 的距离计算得到,具体计算过程如下所示:

$$r^2 = \|\varphi(x_{sv}) - \varphi(a)\|^2 =$$

$$k(x_{sv}, x_{sv}) - 2 \sum_i \alpha_i k(x_i, x_{sv}) + \sum_{i,j} \alpha_i \alpha_j k(x_i, x_j) \quad (11)$$

对于输入的测试样本 z ,它与广义球心的距离 d

可表示为:

$$d = \|\varphi(z) - \varphi(a)\| = k(z, z) - 2 \sum_i \alpha_i k(z, x_i) + \sum_{i,j} \alpha_i \alpha_j k(x_i, x_j) \quad (12)$$

2 基于优化核函数带宽 SVDD 的振动预警模型

SVDD 的性能在很大程度上取决于参数 σ 的选择。从 SVDD 的推导过程来看,基于高斯核函数的 SVDD 超球体性能严重依赖高斯核函数,其中核函数带宽 σ 是高斯核函数唯一可调参数即核心参数。

σ 取值的大小决定了 SVDD 超球体描述边界的复杂程度:

当 σ 过小时,超球体描述边界上以及描述边界外的支撑向量数目会增加,描述边界会更加复杂且逼近 SVDD 的训练样本,这样虽然会提高 SVDD 超球体的描述精确度,但也会导致 SVDD 模型过于敏感,出现描述边界过拟合的问题;

当 σ 过大时,描述边界远离训练样本,会导致 SVDD 模型的精度下降,出现描述边界欠拟合的问题。

2.1 核函数带宽与空间矩阵分散性

结合式(3)和式(5),可以得到如下所示的矩阵形式:

$$L = \alpha^T K \alpha - 1 \quad (13)$$

其中: $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_l]^T$ 。

式(13)中,空间矩阵 K 是由训练数据经过核函数映射后,组成对角线为 1 的对角矩阵,即:

$$K = \begin{bmatrix} k(x_1, x_1) & \cdots & k(x_1, x_l) \\ \vdots & \ddots & \vdots \\ k(x_l, x_1) & \cdots & k(x_l, x_l) \end{bmatrix} \quad (14)$$

由于矩阵 K 是沿着对角线对称的对角矩阵,因此,只需讨论矩阵中的上三角矩阵或下三角矩阵,将上三角矩阵定义为 K_u 。

根据式(13)可知:SVDD 在训练过程得到的信息都包含在空间矩阵中。空间矩阵 K 中的核函数值会影响式(5)的求解,从而影响超球体的建立。

因此,如果能设计出一个具有良好性能的空间矩阵,超球体性能也会良好。

EVANGELISTA P F 等人^{[22]274-275}指出:如果 K 中的值是均匀分布的,则式(5)的解 α 具有合理的稀疏性。

在概率论和数理统计中,方差平均值之比是概率分布离散度的标准度量,其计算公式如下:

$$C_v(\sigma) = \frac{s(\sigma)}{m(\sigma)} \tag{15}$$

式中: $s(\sigma)$ 为标准差; $m(\sigma)$ 为均值。

式(15)可以很好地描述 K_m 中数值的分散性,同时也消除了数据数量级差异的影响,但是当 σ 过小时,会导致 $C_v(\sigma)$ 出现较大的值,且 K_m 中的元素更为集中。因此,在这种情况下, $C_v(\sigma)$ 值不能反映 K_m 中元素的分散状况。

EVANGELISTA P F 等人在式(15)的基础上,提出了新的表征散度的公式,即:

$$g(\sigma) = \frac{s^2(\sigma)}{m(\sigma) + \varepsilon} \tag{16}$$

式中: ε 为无限趋近于 0 的正数。

式(16)是将方差平方并在分母中,引入 ε 来避免分母等于零的情况,使该方法更具实用性;但 ε 如何取值成为了一个新的问题。

LIU Z^[26]²⁴⁻²⁶在 EVANGELISTA P F 等人的基础上提出了方差平方根平均比法。

该方法计算式如下所示:

$$f(\sigma) = \frac{s^2(\sigma)}{\sqrt{m(\sigma)}} \tag{17}$$

如上所述,学者们的研究集中在如何选取合适的 σ ,从而使得 K 中的数据具有良好的分散性。同时,他们逐步改进新的方法,以避免 σ 太小,从而造成分散性良好的假象。

为了避免 σ 太大而造成矩阵 K_m 中的数值无限接近于 1,造成分散性差的状况, σ 的最佳取值范围应与输入 SVDD 中的训练数据的数值范围接近。

笔者提取辛辛那提大学智能维护中心(intelligent maintenance systems,IMS)第二组轴承试验数据集^[29]的谱距离指标趋势因子(spectral distance index trend factor,SDITF)和多尺度散布熵趋势因子(multiscale dispersion entropy trend factor,MDETF)^[30],以此作为 SVDD 训练数据。

IMS 数据 $f(\sigma) - \sigma$ 曲线如图 2 所示。

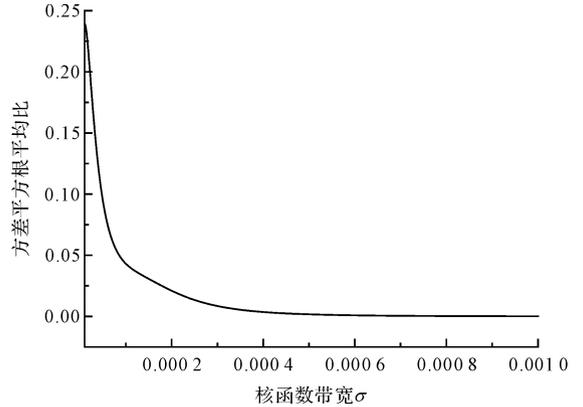


图 2 方差平方根平均比-核函数带宽图

Fig.2 Square root of variance mean ratio-kernel bandwidth graph

由图 2 可知: $f(\sigma) - \sigma$ 曲线在 $[10^{-5}, 10^{-3}]$ 中单调递减,故 σ 的最佳取值为 10^{-5} 。

不同 σ 取值情况下,SVDD 超球体描述边界图如图 3 所示。

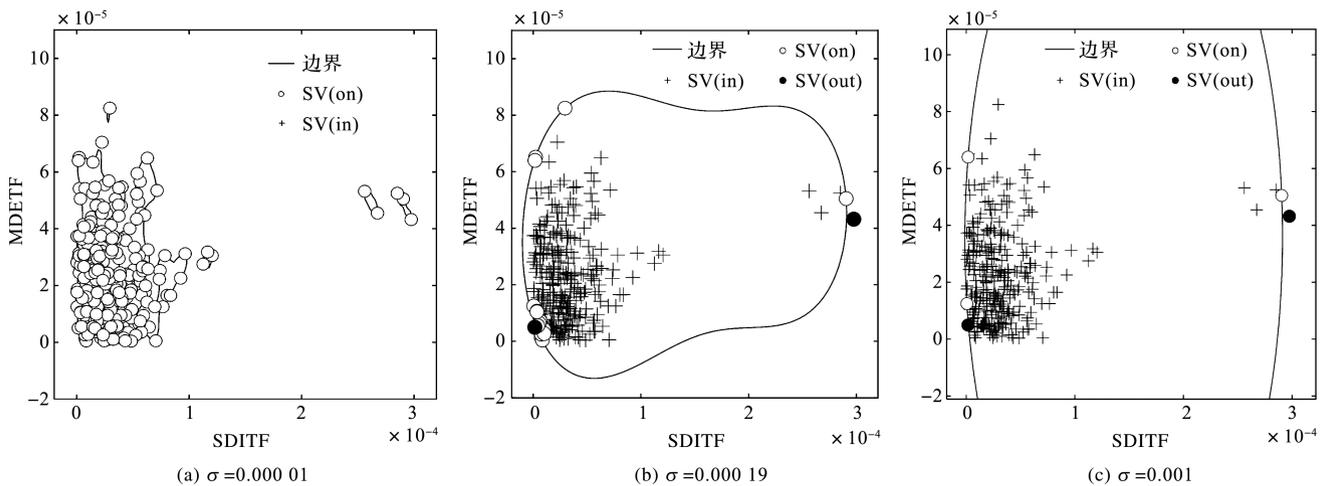


图 3 不同 σ 取值情况下 SVDD 超球体描述边界图

Fig.3 Describe boundary diagram of SVDD hypersphere with different σ values

由图 3 可知:实线为超球体在二维平面的描述边界,当 $\sigma = 10^{-5}$ 时,全部样本均为支持向量,出现了严重的过拟合问题;当 $\sigma = 10^{-3}$ 时,描述边界过于光滑,出现了欠拟合问题;而当 $\sigma = 0.000 19$ 时,描述边界与

样本之间拟合良好,这说明 σ 的取值在 $[10^{-5}, 10^{-3}]$ 时, K 矩阵的分散性并不是单调递减的。

由此可见,LIU Z 等人的方法不适合 SVDD 训练数据数值特别小的情况。

2.2 基于 PSO 与空间矩阵复杂度的优化核函数带宽计算方法

1948 年,美国数学家香农首次提出了信息熵的概念,用于描述信息中排除了冗余后的信息量^[31]。此后,信息熵被广泛应用于生物学、社会学、经济学、信号学、语言学等领域。

一般来说,复杂度高的矩阵分散性更好;复杂度低的矩阵分散性也更低。例如:一个矩阵的数值均为某一常数,其信息熵值为 0。因此,可以通过计算空间矩阵的复杂度(信息熵值)来解决 σ 的取值问题。利用粒子群优化算法寻找空间矩阵 K 复杂度最大时对应的核函数带宽取值,以加快目标函数收敛,降低运算时间。

核函数带宽 σ 与惩罚参数 C 是基于高斯核函数 SVDD 的仅有的 2 个参数。文献[1]56 认为 SVDD 模型对 C 的取值不敏感,当训练数据中不存在异常值时,推荐 C 值取 1。文献[32]的实验结果表明: C 越小,超球体描述边界的约束越紧。

在实际工程应用过程中,无法避免训练数据没有干扰项,因此,笔者将 C 的取值设定为 0.3,以平衡误差项的干扰对超球体大小的影响。

为充分考虑 C 的取值对超球体训练的影响,在利用 PSO 寻优算法计算出最优解的基础上,当 C 的取值小于 1 时,引入惩罚参数 C 对结果进行略微修正,从而自动求解出最佳核函数带宽的取值。

2.3 机械振动故障预警模型

基于优化核函数带宽 SVDD 的机械振动故障预警模型构建流程图,如图 4 所示。

由图 4 可知:基于优化核函数带宽 SVDD 的机械振动故障预警模型的具体流程为:

步骤一。提取旋转机械历史正常运行状态下的振动信号特征值,将其作为 SVDD 的训练数据;

步骤二。将步骤一提取的特征值映射到高维空间

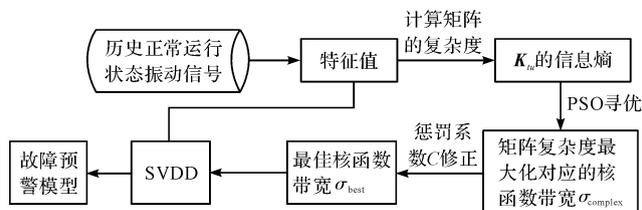


图 4 基于优化核函数带宽 SVDD 的机械振动故障预警模型流程图

Fig.4 Construction flow chart of fault warning model for rotating machinery based on optimized kernel bandwidth SVDD

矩阵 K 中;得到对角线为 1 的对角矩阵 K ,计算对角矩阵 K 的下三角矩阵 K_m 的信息熵;

步骤三。以 K_m 的信息熵值为目标函数,利用 PSO 算法计算出矩阵 K 复杂度最大值对应的核函数带宽取值 $\sigma_{complex}$;

步骤四。采用式(18)计算惩罚参数 C 修正后的最佳核函数带宽 σ_{best} ;

$$\sigma_{best} = \frac{\sigma_{complex}}{C} \quad (18)$$

步骤五。将步骤一提取的振动信号特征值作为 SVDD 训练数据,以步骤四的计算结果为最佳核函数带宽,训练出基于优化核函数带宽 SVDD 的机械振动故障预警模型。

3 实验验证

3.1 实验室数据和工程案例数据验证

为验证优化核函数带宽计算方法的可靠性,笔者收集了辛辛那提大学智能维护中心轴承试验数据集以及西安交通大学轴承实验数据集^[33],以进行实验验证。此外,笔者还收集了 4 项从企业生产过程中获取的工程案例数据,一同进行实验验证。

工程案例所采集目标设备的概貌图如图 5 所示。

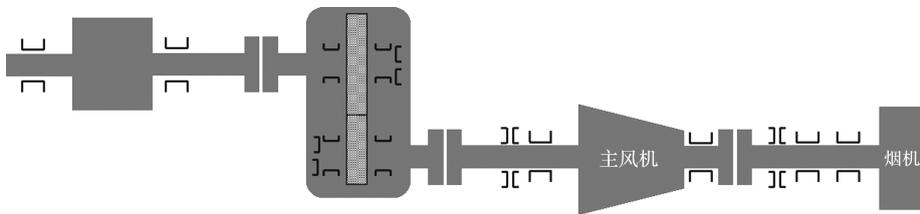


图 5 某石化公司烟气轮机机组概貌图

Fig.5 General view of flue gas turbine unit of a petrochemical company

工程案例烟机 1~4 振动数据集来源于 4 个不同的烟气轮机。转速稳定时,烟机 1~4 数据集采样频率为 3 380 Hz,每间隔 5 min 采集一次振动位移信号。

为确保训练数据足够且可靠,笔者使用历史正常

运行状态数据集(超过 300 组的实验室数据和工程案例数据)进行验证。其中,XJTUx-n 数据集代表西安交通大学第 x 组实验第 n 个轴承的数据,同理 IMSx-n 数据集代表 IMS 中心第 x 组实验第 n 个轴承的数据。此

外,所用粒子群优化算法的代码来源于 Yarpiz 进化算法工具箱^[34],种群数设定为 20,迭代次数设定为 20。

具体实验数据信息如表 1 所示。

表 1 实验数据信息一览表

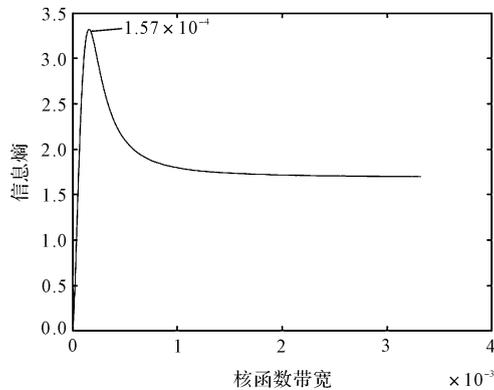
Table 1 Experimental data information list

数据来源	数据集	数据类别	训练数据段
辛辛那提	IMS1-3	全生命周期	201 ~ 500
大学智能	IMS1-4	全生命周期	201 ~ 500
运维中心 (IMS)	IMS2-1	全生命周期	1 ~ 300
	IMS3-3	全生命周期	1 ~ 300
西安交通	XJTU3-2	全生命周期	1 ~ 300
大学(XJTU)	XJTU3-4	全生命周期	1 ~ 300
	烟机-1	历史正常运行数据	1 ~ 300
工程案例	烟机-2	历史正常运行数据	1 ~ 300
数据	烟机-3	历史正常运行数据	1 ~ 300
	烟机-4	历史正常运行数据	1 ~ 300

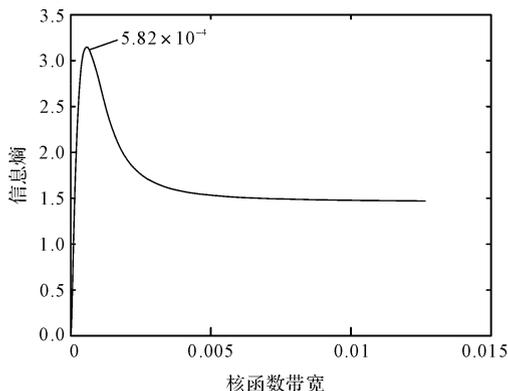
基于 PSO 优化与空间矩阵复杂度的优化核函数带宽计算方法的实用性和可靠性实验验证过程如下所示:

步骤一。提取实验数据的 SDITF 和 MDETf,将其作为 SVDD 训练数据;

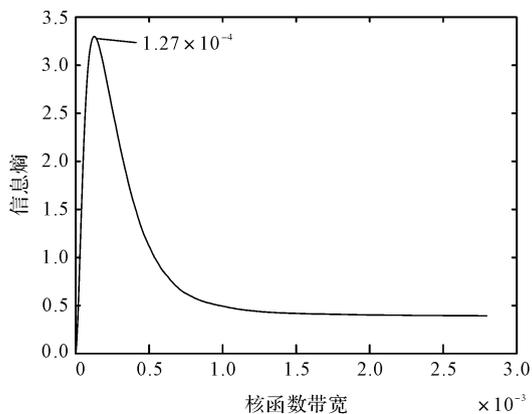
步骤二。应用基于 PSO 优化与空间矩阵复杂度的优化核函数带宽计算方法,计算出各数据集的高斯核函数带宽 σ ,并绘制相应的信息熵-核函数带宽图,如图 6 所示。



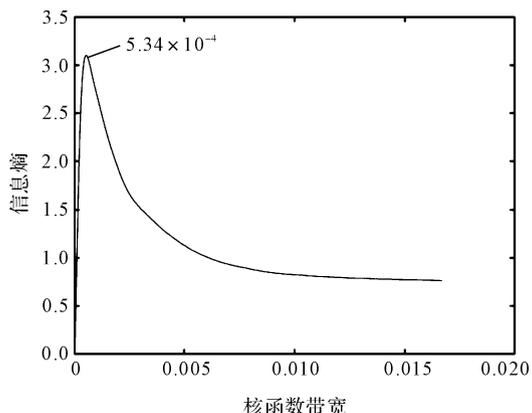
(a) IMS1-3 信息熵-核函数带宽图



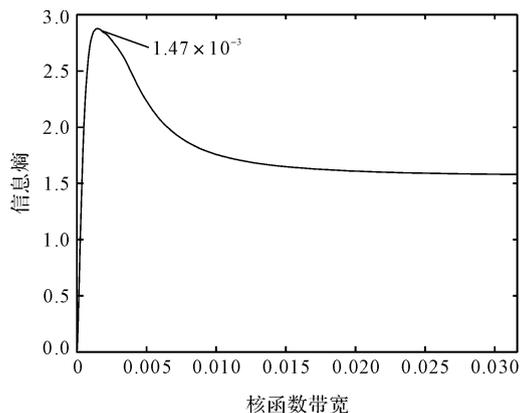
(b) IMS1-4 信息熵-核函数带宽图



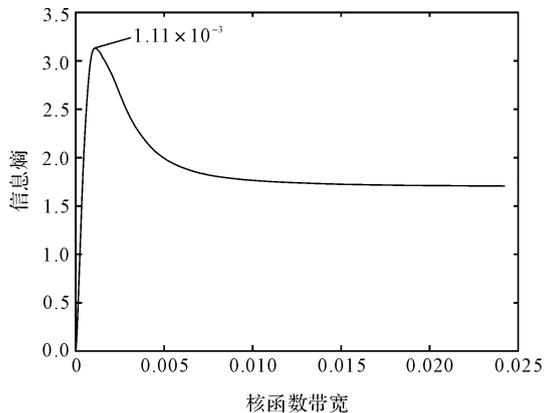
(c) IMS2-1 信息熵-核函数带宽图



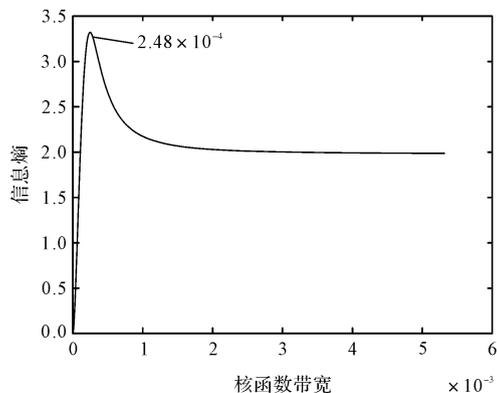
(d) IMS3-3 信息熵-核函数带宽图



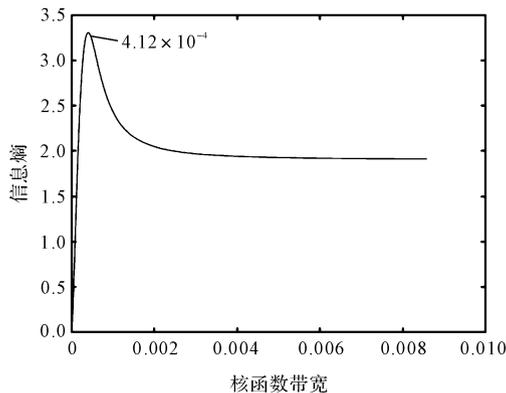
(e) XJTU3-2 信息熵-核函数带宽图



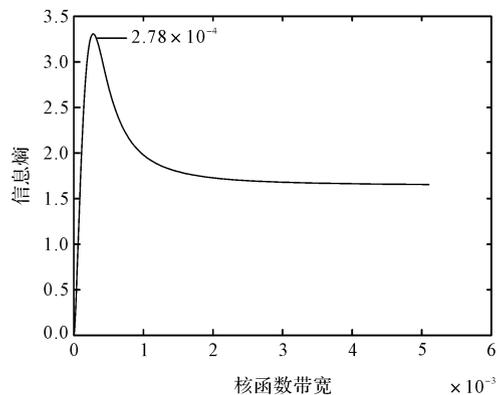
(f) XJTU3-4 信息熵-核函数带宽图



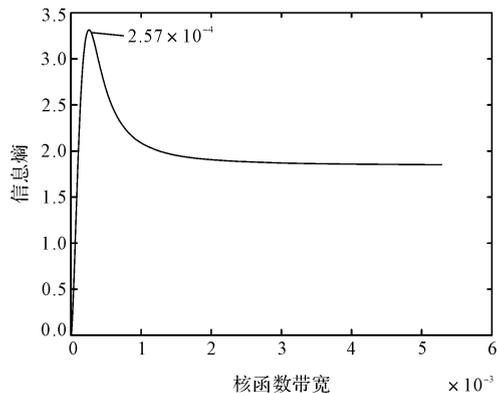
(g) 烟机-1信息熵-核函数带宽图



(h) 烟机-2信息熵-核函数带宽图



(i) 烟机-3信息熵-核函数带宽图



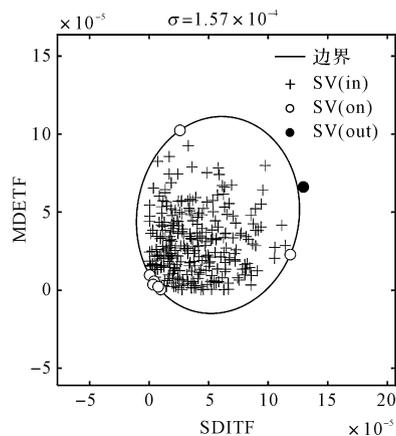
(j) 烟机-4信息熵-核函数带宽图

图 6 不同数据信息熵-核函数带宽图

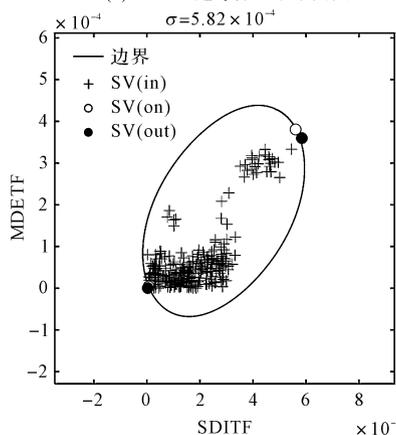
Fig.6 Different data information entropy-kernel bandwidth diagram

由图 6 可知:目标函数为信息熵值,在搜寻范围内均只有一个极大值,避免了 PSO 优化算法容易陷入局部最优的缺陷。假设在 $[10^{-6}, 10^{-3}]$,以精度 10^{-7} 采用遍历计算的方式寻找极值,需要计算 10 000 次,而 PSO 寻优只需要计算 400 次即可(种群规模 $20 \times$ 迭代次数 $20 = 400$)。因此,利用 PSO 寻优的方式求解目标函数的极大值可以加快计算速度,节省计算机资源,便于在工程上进行应用;

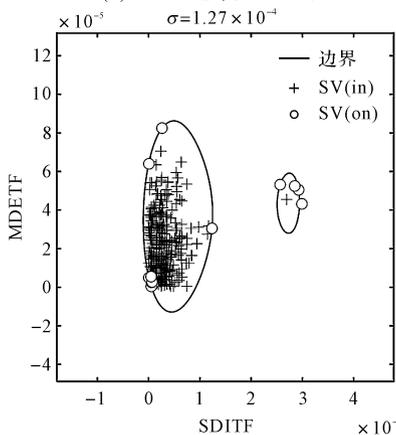
步骤三。通过步骤二计算得到的高斯核函数带宽 σ 以及步骤一提取的 SDITF 和 MDETF,训练 SVDD 超球体,绘制各数据集的二维超球体平面图,如图 7 所示。



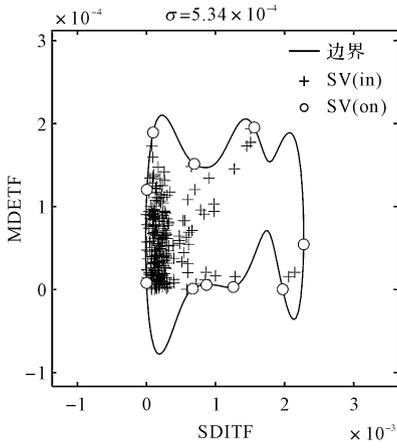
(a) IMS1-3超球体二维平面图



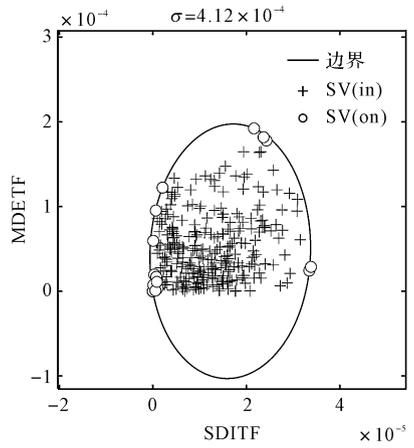
(b) IMS1-4超球体二维平面图



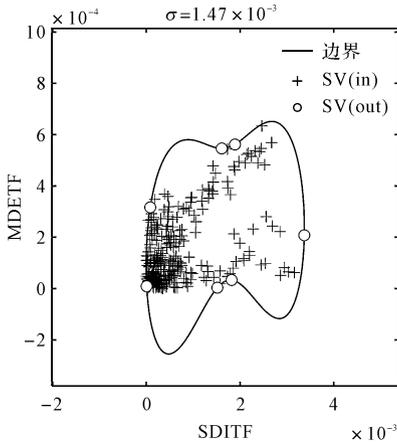
(c) IMS2-1超球体二维平面图



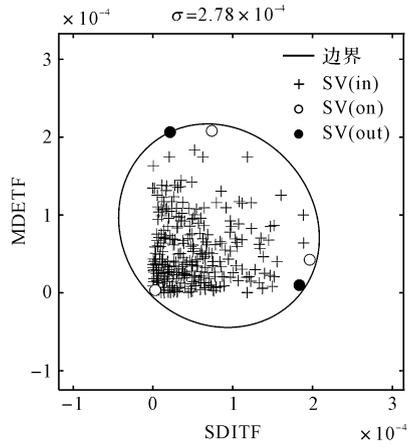
(d) IMS3-3超球体二维平面图



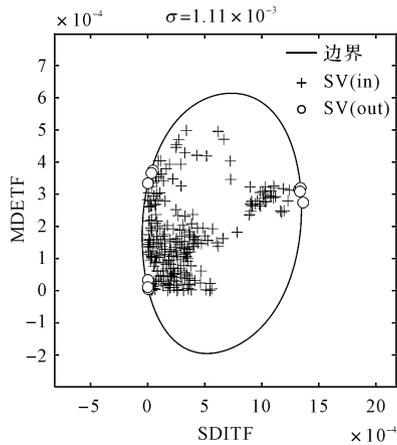
(h) 烟机-2超球体二维平面图



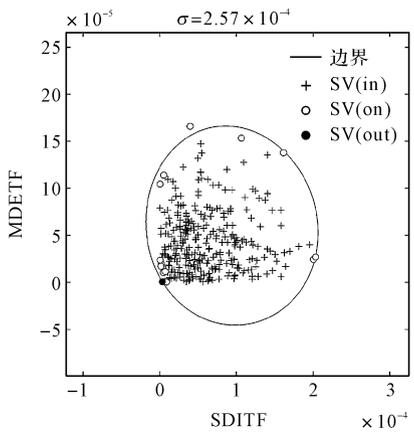
(e) XJTU3-2超球体二维平面图



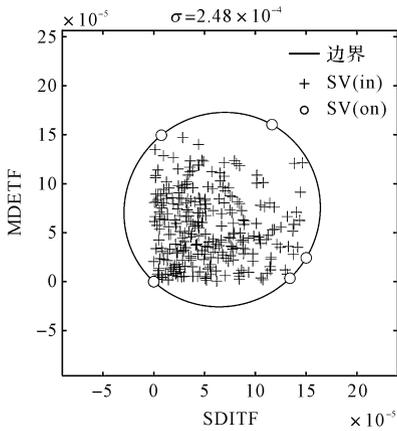
(i) 烟机-3超球体二维平面图



(f) XJTU3-4超球体二维平面图



(j) 烟机-4超球体二维平面图



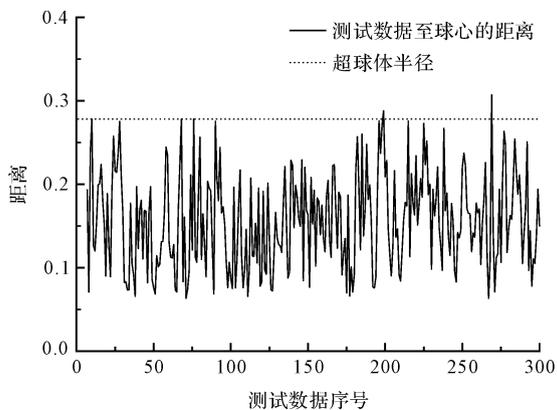
(g) 烟机-1超球体二维平面图

图 7 不同数据超球体二维平面图

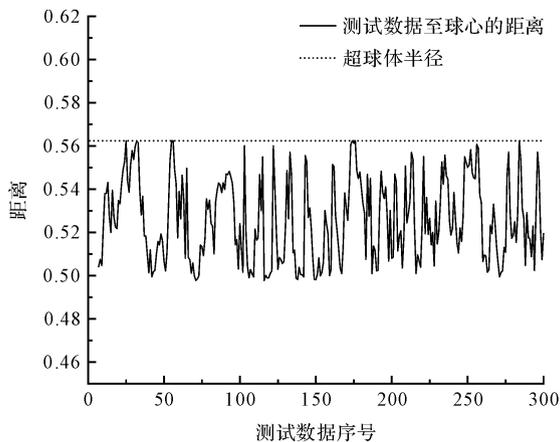
Fig. 7 Two-dimensional plan of hypersphere with different data

由图 7 可知:无论是用公开的实验室数据还是工程案例数据验证,采用该计算方法(基于 PSO 优化与空间矩阵复杂度的优化核函数带宽计算方法)训练出的 SVDD 超球体大小合适,超球体描述边界没有出现拟合或欠拟合的现象,超球体合格率为 100%;

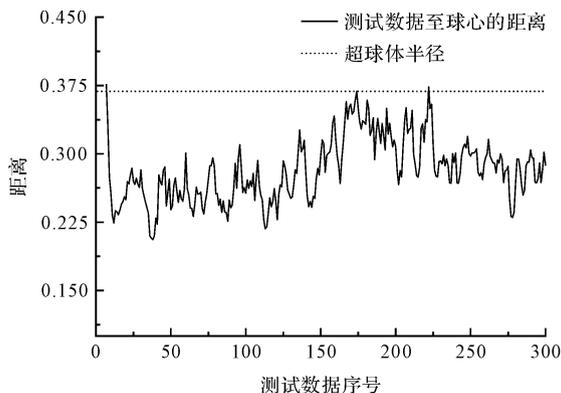
步骤四。将步骤一提取的 SDITF 和 MDETF 作为测试数据依次输入步骤三训练好的超球体中,绘制各测试数据距超球体中心的距离图,如图 8 所示。



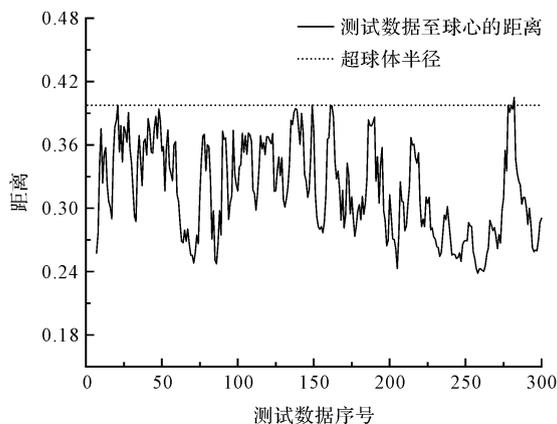
(a) IMS1-3测试数据与超球体球心之间的距离图



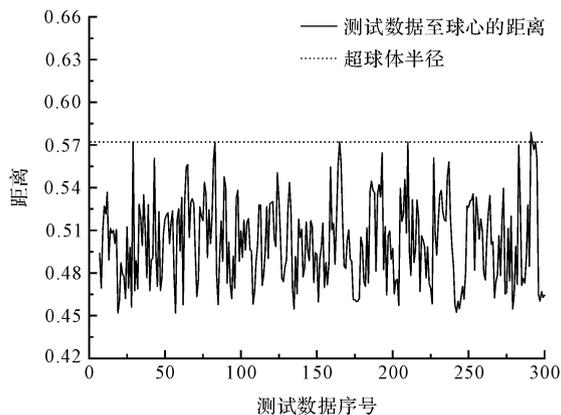
(e) XJTU3-2测试数据与超球体球心之间的距离图



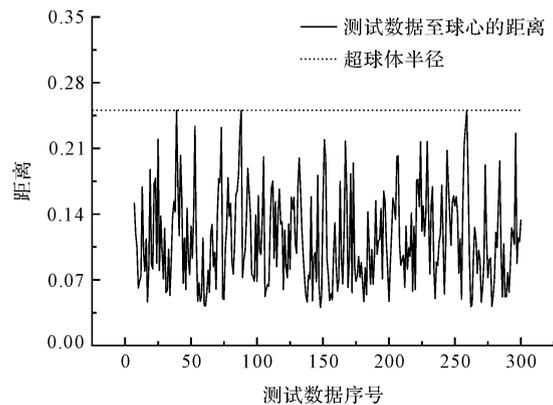
(b) IMS1-4测试数据与超球体球心之间的距离图



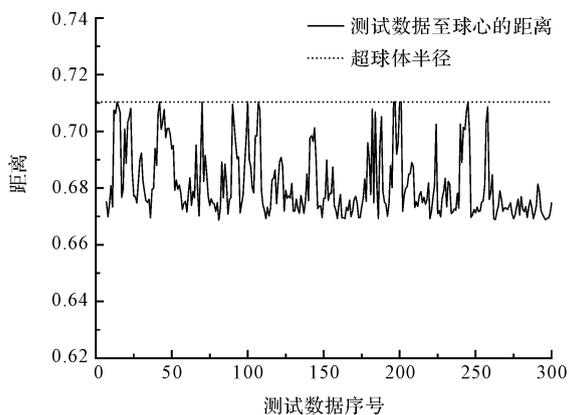
(f) XJTU3-4测试数据与超球体球心之间的距离图



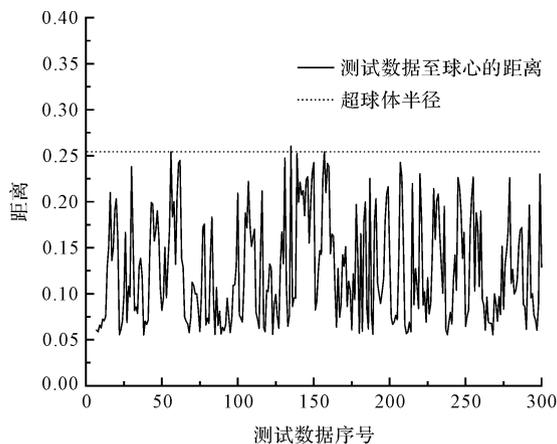
(c) IMS2-1测试数据与超球体球心之间的距离图



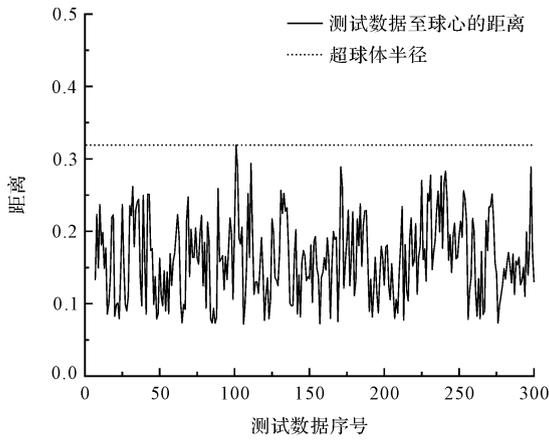
(g) 烟机-1测试数据与超球体球心之间的距离图



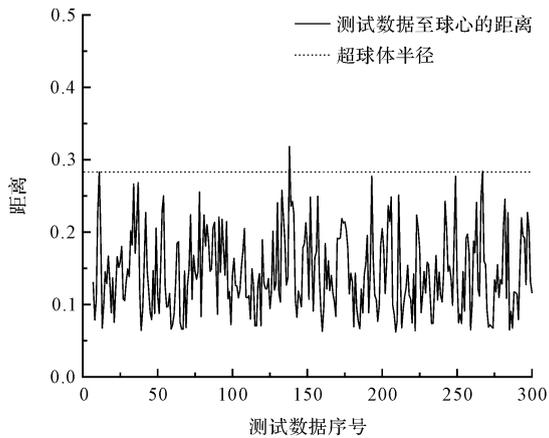
(d) IMS3-3测试数据与超球体球心之间的距离图



(h) 烟机-2测试数据与超球体球心之间的距离图



(i) 烟机-3测试数据与超球体球心之间的距离图



(j) 烟机-4测试数据与超球体球心之间的距离图

图 8 不同数据与超球体球心之间的距离图

Fig. 8 The distance between different data and the center of the hypersphere

由图 8 可知:采用基于 PSO 优化与空间矩阵复杂度的优化核函数带宽计算方法训练出的超球体半径与测试样本贴合良好,没有出现严重的偏离或严重的贴近现象;

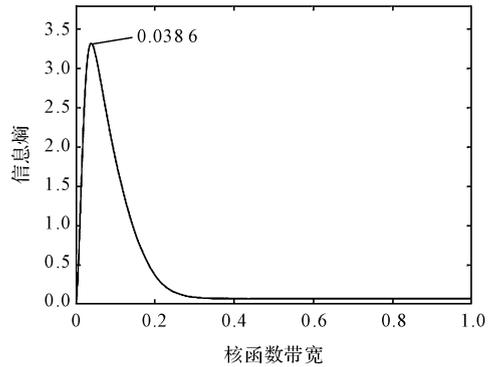
来自 2 个不同实验室的轴承振动加速度数据以及工程案例振动位移数据的实验结果均良好,表明该方法构建的机械振动故障预警模型适用于不同设备的数据,且有很强的鲁棒性。

3.2 较大数值训练数据验证

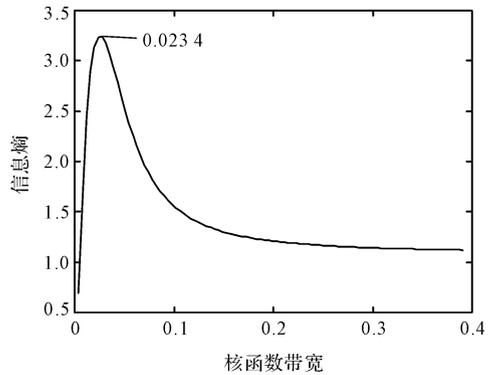
上述实验训练数据的数值较小。为验证基于 PSO 优化与空间矩阵复杂度的优化核函数带宽计算方法在输入 SVDD 训练数据数值较大时,训练出 SVDD 超球体的性能是否良好,笔者提取 IMS2-1 数据集的谱距离指标(spectral distance index trend factor, SDI)与多尺度散布熵(multiscale dispersion entropy trend factor, MDE)、峭度(kurtosis, Ku)与均方根(root mean square, RMS)共 2 组数据,进行了实验验证。

IMS2-1 谱距离指标与多尺度散布熵的信息熵-核

函数带宽图、峭度与均方根的信息熵-核函数带宽图,如图 9 所示。



(a) IMS2-1 谱距离指标与多尺度散布熵的信息熵-核函数带宽图



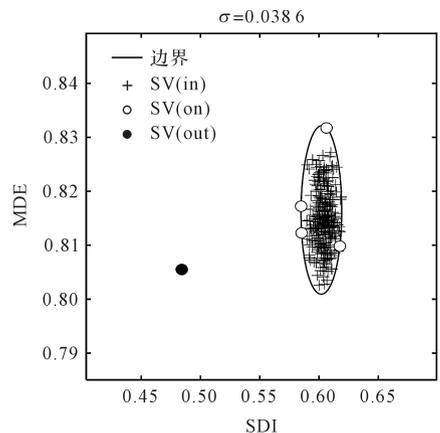
(b) IMS2-1 峭度与均方根的信息熵-核函数带宽图

图 9 IMS2-1 信息熵-核函数带宽图

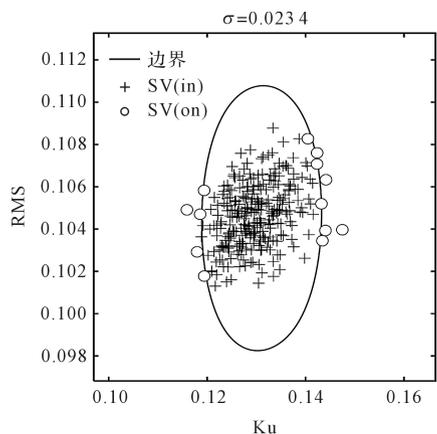
Fig. 9 IMS2-1 information entropy-kernel bandwidth diagram

由图 9 可知:2 组数值较大的训练数据运用优化核函数带宽计算的方法,计算出的核函数带宽取值分别为 0.038 6、0.023 4,没有出现其他的极大值,运用 PSO 寻优算法能够快速收敛,且不会陷入局部最优。

IMS2-1 谱距离指标与多尺度散布的超球体二维平面图,IMS2-1 峭度与均方根的超球体二维平面图,如图 10 所示。



(a) IMS2-1 谱距离指标与多尺度散布的超球体二维平面图



(b) IMS2-1峭度与均方根的超球体二维平面图

图 10 IMS2-1 超球体二维平面图

Fig. 10 IMS2-1 two-dimensional plan of hyperspheres

由图 10 可知:当核函数带宽取值分别为 0.038 6、0.023 4 时,2 组数据训练出的超球体大小适中、超球体描述边界拟合良好。

4 常规方法对比实验

为推动 SVDD 的实际应用,众多学者已做了相关研究。比如,LIU Z 等人^{[26]24-26}提出了通过寻找方差平方根平均比最大值,以此来选择最佳 σ (为方便书写,笔者简称此方法为方法一);SVDD 的原创作者建议最小化支持向量与样本的比率,以此来选择最优 σ (笔者简称此方法为方法二);SHI P 和 CHA M 等人使用 k 折交叉验证的方法不断降低模型的分误差率,以此来寻找最优 σ (笔者简称其为方法三)。

笔者将获取的历史正常运行状态振动数据集随机分为 5 等份,每次使用 4 等份数据来训练 SVDD 超球体,使用剩下的 1 等份数据来验证 SVDD 模型的分误差率。

为方便对比,笔者均选择 IMS2-1 前 300 组数据进行基于 SVDD 的机械振动故障预警模型训练实验。

如图 7(c) 所示:当核函数带宽值取 1.27×10^{-4} 时,用 IMS2-1 数据集提取的 SDITF 和 MDETf 训练出的 SVDD 超球体性能良好。为方便比较,4 种方法均在 $[10^{-5}, 10^{-3}]$ 范围内计算核函数带宽的取值。

常规方法对比验证过程如下:

步骤一。提取 IMS2-1 数据集前 300 组振动数据的 SDITF 和 MDETf;

步骤二。在核函数带宽的范围为 $[10^{-5}, 10^{-3}]$ 内,分别计算出下三角空间矩阵 K_{tt} 的方差平方根平均比(方法一)、支持向量与样本的比率(方法二)、模型的分误差率(方法三)、以及基于 PSO 优化与空间矩

阵复杂度的优化核函数带宽计算方法的空间矩阵 K_{tt} 的信息熵值;

步骤三。根据步骤二中的计算结果,分别绘制方法一的方差平方根平均比-核函数带宽图,如图 11 所示。

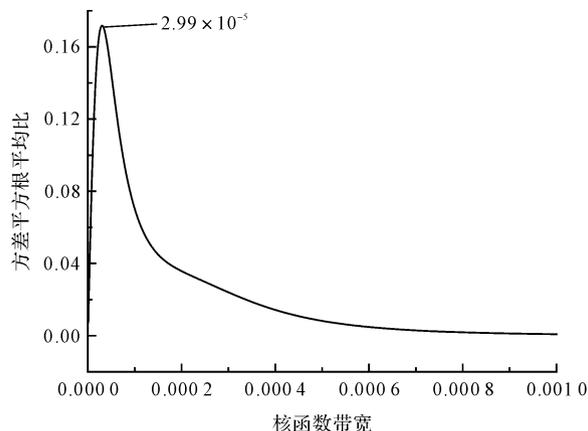


图 11 方差平方根平均比-核函数带宽图

Fig. 11 Square root mean ratio of variance-kernel bandwidth diagram

由图 11 可知:方法一计算出的核函数带宽取值为 2.99×10^{-5} ,没有出现其他的极大值。

方法二的支持向量与样本的比率-核函数带宽图如图 12 所示。

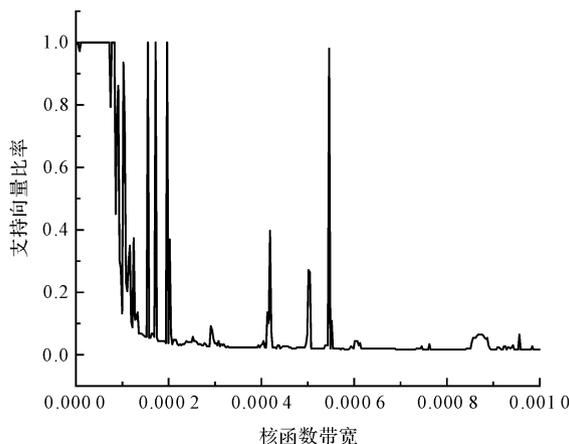


图 12 支持向量与样本的比率-核函数带宽图

Fig. 12 Support vector to sample ratio-kernel bandwidth graph

对于方法二,理论上会出现一个极小值,当核函数带宽取该值时,支持向量比率最小。但在图 12 中,并没有出现清晰的极小值,核函数带宽取值在 4×10^{-4} 之后,有趋近于某一常数的趋势,因此,可以认为无法通过该方法寻找出支持向量比率的极小值。

方法三的分误差率-核函数带宽图如图 13 所示。

对于方法三,理论上也会出现一个极小值,核函数

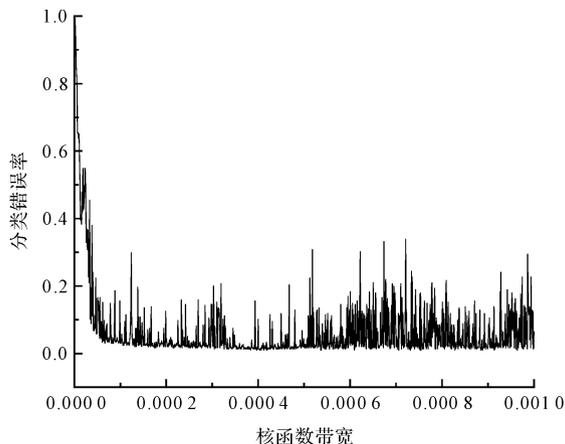
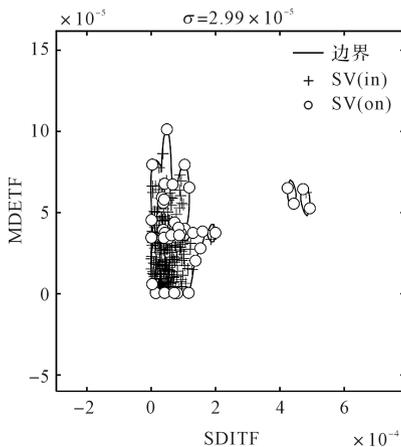


图 13 分类错误率-核函数带宽图

Fig. 13 Classification error rate-kernel bandwidth graph

带宽取该值时,分类错误率最小。但在图 13 中,没有出现清晰的极小值,分类错误率随着核函数带宽取值的变化波动较大,因此,可以认为无法通过该方法寻找分类错误率的极小值。

当核函数带宽取值为 2.99×10^{-5} 时,训练出的超球体二维平面图如图 14 所示。

图 14 $\sigma = 2.99 \times 10^{-5}$ 超球体二维平面图Fig. 14 $\sigma = 2.99 \times 10^{-5}$ two-dimensional plane graph of the hypersphere

由图 14 可知:超球体描述边界过于贴近训练样本,出现了严重的过拟合现象,说明核函数带宽的取值过低。

5 结束语

为解决基于 SVDD 的机械振动故障预警模型在实际应用过程中,存在核函数带宽取值难以确定的问题,笔者提出了一种基于 PSO 优化与空间矩阵复杂度的 SVDD 核函数带宽计算方法。

笔者采用实验室公开数据和工程案例数据的实验结果,以及常规方法的对比实验结果,验证了所构建的

机械振动故障预警模型具有一定的鲁棒性、实用性、先进性和可靠性,并得出以下结论:

1) 利用实验室数据以及工程案例数据(共 10 项数据)训练出的 SVDD 超球体描述边界均拟合良好,超球体合格率 100%,表明该机械振动故障预警模型适用于不同设备的数据,具有很强的鲁棒性;

2) 利用较大数值训练数据训练出的 SVDD 超球体均拟合良好,表明该机械振动故障预警模型具有适用训练数据数值范围较广的特点,具有一定的实用性;

3) 与常规方法的对比试验结果表明,该方法能解决常规方法不收敛、过拟合和欠拟合的问题,具有一定的先进性和可靠性。

接下来,笔者将进一步研究核函数带宽 σ 、惩罚参数 C 与 SVDD 超球体之间的复合影响关系,以进一步增强 SVDD 相关参数的自适应性。

参考文献 (References):

- [1] TAX D M, DUIN R P. Support vector data description[J]. Mach Learn, 2004, 54(1): 45-66.
- [2] LI J J, MENG G Y, LUO J G, et al. Research on the performance degradation assessment method of a mine hoist braking system based on variable step-size fruit fly optimization algorithm-complex Gaussian wavelet support vector data description[J]. Science Progress, 2020, 103(3): 558-566.
- [3] 林扬,何亚东,袁壮,等.基于 PCA-SVDD 的化工过程异常工况检测[J].过程工程学报, 2022, 22(7): 970-978. LIN Yang, HE Ya-dong, YUAN Zhuang, et al. Abnormal condition detection in chemical process based on PCA-SVDD [J]. The Chinese Journal of Process Engineering, 2022, 22(7): 970-978.
- [4] 王晓慧,王延江,邓晓刚,等.基于加权深度支持向量数据描述的工业过程故障检测[J].化工学报, 2021, 72(11): 5707-5716. WANG Xiao-hui, WANG Yan-jiang, DENG Xiao-gang, et al. Industrial process fault detection using weighted deep support vector data description [J]. CIESC Journal, 2021, 72(11): 5707-5716.
- [5] 庞菲菲,温祥西,王晓华.基于 SVDD 去除异常值的水下目标定位方法[J].振动与冲击, 2021, 40(22): 182-187. PANG Fei-fei, WEN Xiang-xi, WANG Xiao-hua. Underwater target localization method by removing the unreliable measurements based on SVDD [J]. Journal of Vibration Shock, 2021, 40(22): 182-187.
- [6] SHI P, LI G H, YUAN Y M, et al. Outlier detection using improved support vector data description in wireless sensor networks[J]. Sensors, 2019, 19(21): 4712.

- [7] 王 斐,房立清,赵玉龙,等. 基于 VMD 和 SVDD 的滚动轴承早期微弱故障检测和性能退化评估研究[J]. 振动与冲击,2019,38(22):224-230,256.
WANG Fei, FANG Li-qing, ZHAO Yu-long, et al. Rolling bearing early weak fault detection and performance degradation assessment based on VMD and SVDD [J]. Journal of Vibration Shock,2019,38(22):224-230,256.
- [8] 赵聪聪,赵颖慧,白 杨,等. 基于可拓学和 SVDD 的轴箱轴承故障监测[J]. 振动与冲击,2020,39(4):63-68.
ZHAO Cong-cong, ZHAO Ying-hui, BAI Yang, et al. Fault monitoring for axlebox bearing based on extenics and support vector data description [J]. Journal of Vibration Shock, 2020,39(4):63-68.
- [9] 刘志远,赵欣洋,王化玲,等. 基于 ACP SO-SVDD 的齿轮箱故障异常检测方法研究[J]. 机电工程,2020,37(4):377-382.
LIU Zhi-yuan, ZHAO Xin-yang, WANG Hua-ling, et al. Anomaly detection of gearbox fault based on ACP SO-SVDD [J]. Journal of Mechanical & Electrical Engineering,2020,37(4):377-382.
- [10] 陈宇晨,何毅斌,戴乔森,等. 基于 EMDD 信息量和 KNP-SVDD 的滚动轴承故障诊断研究[J]. 机电工程,2021,38(1):55-61.
CHEN Yu-chen, HE Yi-bin, DAI Qiao-sen, et al. Fault diagnosis of rolling bearing based on EMDD information and KNP-SVDD [J]. Journal of Mechanical & Electrical Engineering,2021,38(1):55-61.
- [11] 周建民,游 涛,尹文豪,等. 基于融合 FCM-SVDD 模型的滚动轴承退化状态识别[J]. 机械设计与研究,2020,36(1):124-129.
ZHOU Jian-min, YOU Tao, YIN Wen-hao, et al. Degraded state recognition of rolling bearing based on fusion FCM-SVDD mode [J]. Machine Design and Research, 2020,36(1):124-129.
- [12] MAO W, CHEN J, LIANG X, et al. A new online detection approach for rolling bearing incipient fault via self-adaptive deep feature matching [J]. IEEE. Transactions on Instrumentation and Measurement,2020,69(2):443-456.
- [13] YANG C, MAO W, LIU Y, et al. Incremental Weighted Support Vector Data Description Method for Incipient Fault Detection of Rolling Bearing: 2019 Prognostics and System Health Management Conference (PHM-Qingdao) [C]//2019 Prognostics and System Health Management Conference (PHM-Qingdao). IEEE. ,2019:8942864.
- [14] 武千惠,黄必清. 基于支持向量数据描述的剩余寿命预测方法[J]. 计算机集成制造系统,2018,24(11):2725-2733.
WU Qian-hui, HUANG Bi-qing. Remaining useful life prediction based on support vector data description [J]. Computer Integrated Manufacturing Systems, 2018, 24 (11): 2725-2733.
- [15] 张世醒,韩德强,范晓婧. 利用证据理论的多分类支持向量数据描述算法[J]. 西安交通大学学报,2023,57(2):1-9.
ZHANG Shi-xing, HAN De-qiang, FAN Xiao-jing. Multi-class support vector data description based on evidence theory [J]. Journal of Xi'an Jiaotong University, 2023, 57 (2):1-9.
- [16] WANG B, PAN H, YANG W. Robust bearing degradation assessment method based on improved CVA[J]. IET Science, Measurement & Technology,2017,11(5):637-645.
- [17] ZHANG L, QIAO F, WANG J, et al. Equipment health assessment based on improved incremental support vector data description [J]. IEEE. Transactions on Systems, Man, and Cybernetics: Systems,2019,51(5):3205-3216.
- [18] ZHANG C F, PENG K X, DONG J. An incipient fault detection and self-learning identification method based on robust SVDD and RBM-PNN [J]. Journal of Process Control,2020,85(1):173-183.
- [19] CHA M, KIM J S, BAEK J G. Density weighted support vector data description [J]. Expert Systems with Applications,2014,41(7):3343-3350.
- [20] TAX D, YPMA A, DUIN R. Support Vector Data Description Applied to Machine Vibration Analysis [C]//5th Annual Conference of the Advanced School for Computing and Imaging,1999:15-23.
- [21] TAX D, DUIN R. Data Domain Description Using Support Vectors [C]//European Symposium on Artificial Neural Networks,1999:251-256.
- [22] EVANGELISTA P F, EMBRECHTS M J, SZYMANSKI B K. Some Properties of the Gaussian Kernel for One Class Learning [C]//17th International Conference on Artificial Neural Networks Springer, Berlin, Heidelberg, 2007:269-278.
- [23] THEISSLER A, DEAR I. Autonomously Determining the Parameters for SVDD with RBF Kernel from a One-class Training Set [C]//Waste International Conference on Machine Intelligence,2013:1135-1143.
- [24] KHAZAI S, HOMAYOUNI S, SAFARI A, et al. Anomaly detection in hyperspectral images based on an adaptive support vector method [J]. IEEE. Geoscience and Remote Sensing Letters,2011,8(4):646-650.
- [25] WANG H, ZHANG L, XIAO Y, et al. An Approach to Choosing Gaussian Kernel Parameter for One-Class SVMs via Tightness Detecting [C]//Intelligent Human-Machine Systems and Cybernetics (IHMSC),2012 4th International Conference on New York; IEEE. ,2012:318-323.

(下转第 1672 页)

本文引用格式:

刘晓金,陈文武,王庆锋. 基于优化核函数带宽 SVDD 的机械振动预警模型[J]. 机电工程,2023,40(11):1641-1654,1672.

LIU Xiaojin, CHEN Wenwu, WANG Qingfeng. Mechanical vibration warning model based on optimized kernel bandwidth SVDD [J]. Journal of Mechanical & Electrical Engineering, 2023,40(11):1641-1654,1672.

《机电工程》杂志: <http://www.meem.com.cn>

- A time-frequency analysis approach for condition monitoring of a wind turbine gearbox under varying load conditions [J]. *Mechanical Systems and Signal Processing*, 2015, 64 (65):188-216.
- [14] 殷逸冰,文振华. 基于模态分量优化重构和稀疏表达的静电信号联合降噪方法[J]. *仪器仪表学报*, 2022, 43 (2):196-204.
YIN Yi-bing, WEN Zhen-hua. A joint noise reduction method for electrostatic signals with optimized reconfiguration and sparse representation based on modal components[J]. *Chinese Journal of Scientific Instrument*, 2022, 43 (2):196-204.
- [15] 刘若晨. 齿轮传动磨损状态静电综合监测技术研究[D]. 南京:南京航空航天大学民航学院, 2016.
LIU Ruo-chen. Research on Electrostatic Integrated Monitoring Technology for Gear Transmission Wear State [D]. Nanjing: College of Civil Aviation, NUA, 2016.
- [16] 孟乾泰,张玉登,王玉磊,等. 基于小波阈值去噪的煤粉静电信号参数的研究[J]. *国外电子测量技术*, 2020, 39 (5):138-142.
MENG Qian-tai, ZHANG Yu-deng, WANG Yu-lei, et al. Research on the parameters of coal powder electrostatic signal based on wavelet threshold denoising [J]. *Foreign Electronic Measurement Technology*, 2020, 39 (5):138-142.
- [17] 王耀民. 基于 STFT 的跳频信号检测技术研究及实现[D]. 成都:电子科技大学信息与通信工程学院, 2022.
WANG Yao-min. Research and Implementation of STFT-Based Frequency Hopping Signal Detection Technology [D]. Chengdu: School of Information and Communication Engineering, University of Electronic Science and Technology, 2022.
- [18] ZHANG S H, ZHOU J H. State of the art on vibration signal processing towards data driven gear fault diagnosis [J]. *IET Collaborative Intelligent Manufacturing*, 2022, 4 (4):78-83.
- [19] 李康强,冯志鹏. 基于生成微分方程的行星齿轮箱故障振动信号解调分析[J]. *振动与冲击*, 2017, 36(8):9-15.
LI Kang-qiang, FENG Zhi-peng. Analysis of planetary gearbox fault vibration signal demodulation based on generating differential equations [J]. *Journal of Vibration and Shock*, 2017, 36(8):9-15.
- [20] 于欣楠,陈小旺,冯志鹏. 共振频带齿轮故障振动特征分析[J]. *振动工程学报*, 2020, 33(2):424-432.
YU Xin-nan, CHEN Xiao-wang, FENG Zhi-peng. Analysis of vibration characteristics of gear faults in resonant frequency bands [J]. *Journal of Vibration Engineering*, 2020, 33(2):424-432.

本文引用格式:

王可贤,刘若晨,孙见忠. 基于静电信号和短时傅里叶变换的齿轮故障监测方法[J]. *机电工程*, 2023, 40(11):1664-1672.

WANG Kexian, LIU Ruochen, SUN Jianzhong. Gear fault monitoring method based on electrostatic signal and short-time Fourier transform [J]. *Journal of Mechanical & Electrical Engineering*, 2023, 40(11):1664-1672. 《机电工程》杂志; <http://www.meem.com.cn>

(上接第 1654 页)

- [26] LIU Z, KANG J, ZHAO X, et al. Modeling of the safe region based on support vector data description for health assessment of wheelset bearings [J]. *Applied Mathematical Modelling*, 2019, 73(9):19-39.
- [27] MGC A, RAN C B, LIANG Z C, et al. Particle swarm optimization for network-based data classification [J]. *Neural Networks*, 2019, 110(2):243-255.
- [28] JIANG J J, WEI W X, SAO W L, et al. Research on large-scale Bi-level particle swarm optimization algorithm [J]. *IEEE Access*, 2021, 9(4):56364-56375.
- [29] QIU H, LEE J, LIN J, et al. Wavelet filter-based weak signature detection method and its application on rolling element bearing prognostics [J]. *Journal of Sound & Vibration*, 2006, 289(4-5):1066-1090.
- [30] WANG Q, LIU X, WEI B, et al. Online incipient fault detection method based on improved I1 trend filtering and support vector data description [J]. *IEEE Access*, 2021, 9 (2):30043-30059.
- [31] SHANNON, C. E. A mathematical theory of communication [J]. *Bell Systems Technical Journal*, 1948, 27(4):623-656.
- [32] 朱孝开,杨德贵. 基于推广能力测度的多类 SVDD 模式识别方法[J]. *电子学报*, 2009, 37(3):464-469.
ZHU Xiao-kai, YANG De-gui. Multi-class support vector domain description for pattern recognition based on a measure of expansibility [J]. *Acta Electronica Sinica*, 2009, 37(3):464-469.
- [33] WANG B, LEI Y, LI N, et al. A hybrid prognostics approach for estimating remaining useful life of rolling element bearings [J]. *IEEE Transactions on Reliability*, 2018, 69(1):401-412.
- [34] MOSTAPHA KH. YPEA: Yarpiz evolutionary algorithms [J]. *Information Sciences*, 2001, 133(3-4):101-102.