

DOI:10.3969/j.issn.1001-4551.2022.01.010

多分类边界支持矩阵机及其在滚动轴承故障诊断中的应用*

马文静¹, 李 鑫², 张 云³

(1. 河北机电职业技术学院 信息工程系, 河北 邢台 054000; 2. 河南科技大学 机电工程学院, 河南 洛阳 471003; 3. 洛阳轴承研究所有限公司 技术中心, 河南 洛阳 471039)

摘要: 由于支持矩阵机(SMM)利用平行超平面实现对不同类别样本的分类,使其无法最大化任意两类样本之间间隔,为此,通过分析非平行超平面与支持矩阵机的相关理论,提出了一种多分类边界支持矩阵机(MBSMM),并将其应用于滚动轴承的故障诊断中。首先,在MBSMM中以矩阵为建模元素,建立了其多分类目标函数,充分利用输入矩阵行与列之间的结构化信息;然后,利用非平行边界超平面来隔离任意两种类型的数据,非平行边界超平面可以最大化任意两类样本之间的间隔;引入了逐次超松弛法(SOR)进行对偶问题求解,SOR可以线性收敛到最优值,不需要太多计算就可以处理大规模数据集,大大提高了算法的计算效率;最后,将其应用于滚动轴承的故障诊断中,通过滚动轴承数据及不同指标对其进行了实验验证。研究结果表明:MBSMM利用非平行边界超平面可以完成对复杂数据样本的准确分类,在识别率、时间、kappa、准确率、召回率、F1得分和统计检验等方面具有良好表现,证明了RSMM具有优越的分类性能。

关键词: 多分类边界支持矩阵机;滚动轴承;故障诊断;非平行边界超平面

中图分类号:TH133.33

文献标识码:A

文章编号:1001-4551(2022)01-0065-06

Multi-class bounded support matrix machine and its application in rolling bearing fault diagnosis

MA Wen-jing¹, LI Xin², ZHANG Yun³

(1. Department of Information Engineering, Hebei Institute of Mechanical and Electronic Technology, Xingtai 054000, China; 2. School of Mechanical and Electrical Engineering, Henan University of Science and Technology, Luoyang 471003, China; 3. Technology Center, Luoyang Bearing Research Institute Co., Ltd., Luoyang 471039, China)

Abstract: In order to solve the problem that support matrix machine (SMM) used parallel hyperplanes to classify different types of samples, which could not maximize the interval between any two types of samples. By analyzing the related theories of nonparallel hyperplane and SMM, a multi-class bounded support matrix machine (MBSMM) was proposed. It was applied to the fault diagnosis of rolling bearing. Firstly, in MBSMM, the multi classification objective function was established with the matrix as the modeling element, which made full use of the structured information between the rows and columns of the input matrix. Then, the nonparallel bounded hyperplane was used to isolate any two types of data, and the hyperplane could maximize the interval between any two types of samples. The successive overrelaxation (SOR) method was introduced to solve the dual problem. SOR could converge linearly to the optimal value, and could deal with large-scale data sets without too much calculation, which greatly improved the computational efficiency of the algorithm. Finally, it was applied to the fault diagnosis of rolling bearing. It was verified by rolling bearing data and different indexes. The experimental results show that MBSMM can accurately classify complex data samples by using nonparallel bounded hyperplane, which proves the MBSMM has superior classification performance in recognition rate, time, kappa, accuracy, recall rate, F1 score and statistical test.

Key words: multi-class bounded support matrix machine(MBSMM); rolling bearing; fault diagnosis; nonparallel bounded hyperplane

收稿日期:2021-08-03

基金项目:国家自然科学基金资助项目(U1804145)

作者简介:马文静(1981-),女,河北邢台人,硕士研究生,副教授,主要从事自动控制、信息技术、软件开发方面的研究。E-mail:ma_wenjing@

0 引 言

作为一种极其重要的基础部件,滚动轴承被广泛应用于航空发动机、数控机床、风力发电机组等各种传动系统中。但是,由于滚动轴承工作环境通常较为恶劣,其局部极易产生疲劳破坏。

当滚动轴承出现失效时,如不及时排除故障,将有可能造成巨大的经济损失或重大的安全事故。因此,滚动轴承故障诊断对保证机械系统高效、安全运行具有重要意义^[1-3]。

随着人工智能的兴起,各种基于机器学习的滚动轴承故障诊断方法被陆续提出,如支持向量机(support vector machine, SVM)、人工神经网络(artificial neural network, ANN)等^[4,5]。其中,SVM采用结构风险最小化(structural risk minimization, SRM)的分类策略,具有较强的泛化能力和小样本学习能力^[6]。因此,SVM一直是智能滚动轴承故障诊断领域的研究热点。然而,基于支持向量机的滚动轴承故障诊断方法大都需要人工提取滚动轴承固有的故障特征,这将破坏时域信号数据之间的关联性。同时,当故障信息比较微弱时,提取特征很可能造成微弱信息的泄露,致使建立的模型失真^[7]。

为了解决上述问题,LUO Luo 等人^[8]设计了一种矩阵形式的支持矩阵机(support matrix machine, SMM),SMM的核心思想是以矩阵的形式构造一个超平面,来划分不同的类。在SMM算法中,SMM采用核范数来控制权矩阵的秩,充分捕获嵌入到矩阵数据中的结构信息。

鉴于SMM良好的分类能力,相关学者在SMM基础上开发了一系列改进的SMM方法,如ZHENG Qing-qing 等人^[9]采用多分类策略提出了多分类支持矩阵机(multiclass support matrix machine, MSMM),解决了SMM多分类的问题。同时,ZHENG Qing-qing 等人^[10]继续探索数据的冗余性和鲁棒性,提出了稀疏支持矩阵机(sparse support matrix machine, SSMM),其通过增加 L_1 范数来减弱冗余特征和含噪特征对建模的影响,提高了分类的精度。PAN Hai-yang 等人^[11]利用辛几何相似变换和最小二乘法求解决策函数,提出了辛几何矩阵机(symplectic geometry matrix machine, SGMM),增强了模型的鲁棒性和收敛性。

然而,上述SMM及改进算法所建立的超平面都是平行超平面,无法最大化两类复杂数据样本之间的距离。

针对上述问题,笔者提出一种基于多分类边界支

持矩阵机(MBSMM),并应用于滚动轴承故障诊断中。

该方法通过建立多分类目标函数,利用非平行边界超平面来隔离任意两种类型的数据,非平行边界超平面可以最大化任意两类样本之间的间隔,达到预期的分类效果;同时,在MBSMM中引入逐次超松弛法(successive overrelaxation, SOR)^[12],可以大大提高算法的效率。

最后为了验证MBSMM在滚动轴承故障诊断中的有效性,笔者将其与经典矩阵分类器进行比较分析。

1 多分类边界支持矩阵机

给定一训练样本集 $\{\mathbf{Z}_i, y_i\}_{i=1}^N$ (其中: \mathbf{Z}_i —输入矩阵, $\mathbf{Z}_i \in \mathbf{R}^{p \times q}$; y_i —一类标签, $y_i = \{1, 2, \dots, k\}$),拟根据矩阵特点建立目标函数。

对于 k 类分类问题,基于 k 次超平面离第 k 类样本集越近,离其他类样本集越远的原则,笔者建立MBSMM的目标函数,其表达式如下:

$$\min \frac{1}{2} \sum_{i \in U_k} \|tr(\mathbf{W}_k \mathbf{Z}_i) + b_k\|^2 + c_k \sum_{j \in U_k} \xi_j + \frac{1}{2} \lambda_k (\|\mathbf{W}_k\|^2 + b_k^2)$$

$$\text{s. t. } \xi_j \geq 1 + (tr(\mathbf{W}_k \mathbf{Z}_j) + b_k), \xi_j \geq 0 \quad (1)$$

式中: \mathbf{W}_k —第 k 个近端超平面的权矩阵; b_k —第 k 个近端超平面的偏差; U_k —正类样本集; \tilde{U}_k —负类样本集; c_k —折衷系数; λ_k —正则化参数; ξ_j —错误标记误差的松弛变量。

通过引入非负拉格朗日乘子 α 和 β ,实现了目标函数(1)的拉格朗日变换。其表达式如下:

$$L = \frac{1}{2} \sum_{i \in U_k} \|tr(\mathbf{W}_k \mathbf{Z}_i) + b_k\|^2 + c_k \sum_{j \in U_k} \xi_j + \frac{1}{2} \lambda_k (\|\mathbf{W}_k\|^2 + b_k^2) + \sum_{j \in \tilde{U}} \alpha_j (tr(\mathbf{W}_k \mathbf{Z}_j) + b_k + 1 - \xi_j) - \sum_{j \in \tilde{U}} \beta_j \xi_j \quad (2)$$

为解式(2),笔者计算了 \mathbf{W}_k 、 b_k 、 ξ_j 、 α_j 和 β_j 的偏导数,得到了满足Karush-Kuhn-Tucker(KKT)条件的方程:

$$\begin{cases} \partial_{\mathbf{W}_k} L = \sum_{i \in U_k} (tr(\mathbf{W}_k \mathbf{Z}_i) + b_k) \mathbf{Z}_i + \lambda_k \mathbf{W}_k + \sum_{j \in \tilde{U}} \alpha_j \mathbf{Z}_j \\ \partial_{b_k} L = \sum_{i \in U_k} (tr(\mathbf{W}_k \mathbf{Z}_i) + b_k) + \lambda_k b_k + \sum_{j \in \tilde{U}} \alpha_j \\ \partial_{\xi_j} L = c_k - \alpha_j - \beta_j \\ \xi_j \geq 1 + (tr(\mathbf{W}_k \mathbf{Z}_j) + b_k), \xi_j \geq 0 \\ \sum_{j \in \tilde{U}} \alpha_j (tr(\mathbf{W}_k \mathbf{Z}_j) + b_k + 1 - \xi_j) = 0, \alpha_j \geq 0 \\ \sum_{j \in \tilde{U}} \beta_j \xi_j = 0, \beta_j \geq 0 \end{cases} \quad (3)$$

通过整理式(3),可得:

$$\sum_{i \in U_k} \begin{pmatrix} \mathbf{Z}_i \\ \mathbf{I} \end{pmatrix} (\tilde{\mathbf{X}}_i - \mathbf{I}) \begin{pmatrix} \mathbf{W}_k \\ b_k \mathbf{I} \end{pmatrix} + \lambda_k \begin{pmatrix} \mathbf{W}_k \\ b_k \mathbf{I} \end{pmatrix} + \sum_{j \in U_k} \alpha_j \begin{pmatrix} \mathbf{Z}_j \\ \mathbf{I} \end{pmatrix} = 0 \quad (4)$$

式中: \mathbf{I} — $1 \times q$ 矩阵,其元素为 1; $\tilde{\mathbf{Z}}_i$ —输入矩阵向量化。

如果 $\mathbf{Y}_i = (\mathbf{Z}_i \mathbf{I})^T$ 被定义,那么有:

$$\left(\sum_{i \in U_k} \mathbf{Y}_i \mathbf{Y}_i^T + \lambda_k \right) \begin{pmatrix} \mathbf{W}_k \\ b_k \mathbf{I} \end{pmatrix} + \sum_{j \in U_k} \alpha_j \mathbf{Y}_j = 0 \quad (5)$$

$$\begin{pmatrix} \mathbf{W}_k \\ b_k \mathbf{I} \end{pmatrix} = - \left(\sum_{i \in U_k} \mathbf{Y}_i \mathbf{Y}_i^T + \lambda_k \right)^{-1} \sum_{j \in U_k} \alpha_j \mathbf{Y}_j \quad (6)$$

接下来,笔者用式(6)代替拉格朗日函数(2),得到问题(1)的对偶问题:

$$\max \sum_{j \in U_k} \alpha_j - \frac{1}{2} \sum_{j_1 \in U_k} \sum_{j_2 \in U_k} \alpha_{j_1} \alpha_{j_2} \mathbf{Y}_{j_1}^T \left(\sum_{i \in U_k} \mathbf{Z}_i \mathbf{Z}_i^T + \lambda_k \right)^{-1} \mathbf{Y}_{j_2} \quad (7)$$

s. t. $0 \leq \alpha_j \leq c_k$

也可以表示为:

$$\max \mathbf{e}^T \boldsymbol{\alpha} - \frac{1}{2} \boldsymbol{\alpha}_{j_1} \boldsymbol{\alpha}_{j_2} \mathbf{Y}_{j_1}^T \left(\sum_{i \in U_k} \mathbf{Y}_i \mathbf{Y}_i^T + \lambda_k \mathbf{I} \right)^{-1} \mathbf{Y}_{j_2} \quad (8)$$

s. t. $0 \leq \alpha_j \leq c_k$

因此,求解式(1)的问题转化为对偶问题(8)中 $\boldsymbol{\alpha}$ 的解,并且可由式(6)构造第 k 个近端超平面。

为了获得 $\boldsymbol{\alpha}$, 设 $\mathbf{Q} = \mathbf{Y}_{j_1}^T \left(\sum_{i \in U_k} \mathbf{Y}_i \mathbf{Y}_i^T + \lambda_k \mathbf{I} \right)^{-1} \mathbf{Y}_{j_2}$, 可得:

$$\max \mathbf{e}^T \boldsymbol{\alpha} - \frac{1}{2} \boldsymbol{\alpha}^T \mathbf{Q} \boldsymbol{\alpha} \quad (9)$$

s. t. $0 \leq \alpha_j \leq c_k$

为了解决式(9)的问题,可以用 SOR 方法求解。同时, SOR 可以线性收敛到最优值,不需要太多计算就可以处理大规模数据集,因此,笔者取收敛误差阈值 0.01。

用 SOR 法求出 $\boldsymbol{\alpha}$ 值,得到权矩阵 \mathbf{W}_k 和偏差 b_k ,进而可预测未知样本 $\tilde{\mathbf{X}}$ 的状态类型。

如上所述, MBSMM 作为近端分类器,如果未知样本 $\tilde{\mathbf{X}}$ 更接近一个近端超平面,它将被分配到相应的类型,即:

$$\tilde{y} = \min \left(\frac{|\text{tr}(\mathbf{W}_k^T \tilde{\mathbf{X}}) + b_k|}{\|\mathbf{W}_k\|} \right), k = 1, 2, \dots, K \quad (10)$$

根据式(10),笔者通过比较特征矩阵和不同交互超平面之间的距离,来确定样本的类型。

2 基于相关支持矩阵机的诊断方法

当滚动轴承发生故障时,其采集的振动信号通常与正常状态下的振动信号在时域上略有不同,但是很

难直接观察到故障状态,需要采用机器学习方法对采集的信号进行学习,建立状态预测模型。

基于支持向量机的滚动轴承故障诊断方法都需要人工提取滚动轴承固有的故障特征,这将破坏时域信号数据之间的关联性。同时,当故障信息比较微弱时,提取特征很可能造成微弱信息的泄露,致使建立的模型失真。

为此,笔者提出了一种基于多分类边界支持矩阵机(MBSMM)的滚动轴承故障诊断方法。该方法以矩阵为建模单元,充分利用原始信号的微弱信息建立准确的预测模型。

辛几何相似变换(symplectic geometry similarity transformation, SGST)作为一种新的信号分析方法^[13],已被证明具有良好的特征提取能力。因此,笔者拟采用 SGST 分析原始信号,以获得可以保存完整结构信息的特征矩阵。

实验方法的过程如下:

- (1) 将拾取的振动信号进行辛几何相似变换,获得具有原始信号状态信息的辛几何系数矩阵;
- (2) 将获得的辛几何系数矩阵分为训练样本和测试样本,对训练样本进行训练并建立预测模型(10);
- (3) 对测试样本进行测试分类,获得分类结果。

3 实验及结果分析

3.1 实验台及参数设置

为了验证该方法的有效性,笔者选用滚动轴承故障数据进行比较与分析。实验中所使用的滚动轴承型号为 SKF6205,环境温度为 31 °C,同时采用黄油润滑脂润滑。

滚动轴承故障模拟实验台如图 1 所示。




图1 滚动轴承故障模拟实验台

为了模拟滚动轴承不同的故障类型,笔者采用电火花加工技术,分别在轴承的内圈、外圈和滚动体上切割出不同尺寸(0.4 mm、0.2 mm 和 0.3 mm)的“故障”;同时,利用 LMS 软件在测试轴承底座上采集加速度振动

信号,每类滚动轴承状态采集 200 个样本(一个样本包含 2 048 个点)。

实验条件及参数设置如表 1 所示。

表 1 实验条件及参数设置

滚动轴承状态类型	故障深度 /mm	采样频率	转速 /r · min ⁻¹	加载 /Nm
正常	0			
内圈故障	0.2	10 k	900	2
	0.4			
外圈故障	0.2			
	0.3			
滚动体故障	0.2			

3.2 实验结果分析

在实验验证过程中,为了避免单次实验的偶然性,笔者随机抽取 100 个训练样本和 100 个测试样本,进行 5 次独立的测试实验。

同时,笔者对 SGMM、SSMM 和 MSMM 进行了比较分析。

4 种分类器的测试结果如图 2 所示。




图 2 4 种分类器的识别结果

由图 2 可以看出:

在每次试验中, MBSMM 对滚动轴承状态监测的识别率均最高,说明所提方法在滚动轴承故障诊断中具有较大的分类优势;

在所有方法中, MSMM 的故障诊断效果最差,这是由于 MSMM 对数据的要求较高,数据复杂度和数据长度会导致 MSMM 不收敛;

SGMM 具有较好的鲁棒性,测试结果表现良好,但该方法没有考虑信号的稀疏性;

SSMM 具有较高的识别率,其具有较强的泛化能力和鲁棒性。然而,SSMM 不能捕捉到原始振动信号的结构信息,同时该方法的本质是建立平行超平面,完成不同类型数据的划分,无法得到令人满意的结果。

综上所述,与 MSMM、SGMM 和 SSMM 相比,所提方法可通过建立多分类目标函数,利用非平行边界超平面来隔离任意两种类型的数据,非平行边界超平面可以最大化任意两类样本之间的间隔,达到预期的分类效果。因此, MBSMM 具有优越的滚动轴承故障诊

断性能。

为了进一步验证所提方法的分类效果,笔者继续选取 12 种类型的滚动轴承状态数据进行验证。

滚动轴承参数及实验条件及参数设置如表 2 所示。

表 2 实验条件及参数设置

滚动轴承状态类型	故障深度 /mm	加载 /Nm	转速 / (r · min ⁻¹)
正常	0	2	900
			1 200
内圈故障			900
			1 200
外圈故障	900		
	1 200		
滚动体故障	900		
	1 200		

笔者随机选取 100 个样本进行训练,100 个样本作为测试。

经过测试样本分析,4 种方法的识别率 and 对比结果如图 3 所示。




图 3 4 种分类方法的识别结果

从图 3 可以看出: MBSMM 具有较高的识别率,平均识别率比 SGMM 高 2% ~ 5%,比 MSMM 高 3% ~ 8%,比 SSMM 高 0.5% ~ 3%。

为了全面验证所提出的方法,笔者引入 kappa、准确率、召回率和 F1 得分,进行多角度比较分析^[14]。

4 种分类器在 4 种指标下的五次随机实验的结果,如表 3 所示。

由表 3 可以看出:笔者提出的 MBSMM 方法在各个指标上都具有优越的分类性能,并且优于其他分类方法。这是因为 MBSMM 采用所提方法,利用非平行边界超平面来隔离任意两种类型的数据,非平行边界超平面可以最大化任意两类样本之间的间隔。同时,与辛几何相似变换相结合,使模型具有鲁棒性,减弱噪声对分类结果的影响。

表 3 4 种分类器在 4 种指标下的对比结果

	Kappa	准确率	召回率	F ₁ 得分	时间/s
MBSMM	0.984 2 ± 0.006 3	0.982 5 ± 0.005 8	0.982 5 ± 0.004 2	0.982 5 ± 0.004 2	1.025 8 ± 0.095 2
SGMM	0.945 8 ± 0.009 4	0.959 6 ± 0.008 5	0.954 5 ± 0.008 5	0.954 5 ± 0.008 4	1.852 5 ± 0.458 2
SSMM	0.954 7 ± 0.009 4	0.960 5 ± 0.008 6	0.963 6 ± 0.004 5	0.963 6 ± 0.004 5	6.141 5 ± 0.852 4
MSMM	0.921 2 ± 0.012 0	0.920 4 ± 0.011 1	0.927 8 ± 0.026 6	0.927 7 ± 0.026 5	9.254 1 ± 0.275 7

因此,MSMM、SSMM 和 SGMM 在多分类、数据复杂的情况下,分类能力稍显不足。

3.3 统计指标分析

但是上述实验仅从各种判别指标来分析各种分类器的性能,并没有从统计理论上进行分析。因此,为了验证所提 MBSMM 方法是否比其他分类器有所改进,笔者使用 Friedman 检验(Friedman 已经在其他统计检验中得到证明)来评估多分类器的性能^[15]。

Friedman 统计方法的表达式如下:

$$\chi_F^2 = \frac{12N}{k(k+1)} \left[\sum_j R_j^2 - \frac{k(k+1)^2}{4} \right] \quad (11)$$

$$F_F = \frac{(N-1)\chi_F^2}{N(k-1) - \chi_F^2} \quad (12)$$

式中:*N*—分类类型数目;*k*—分类器个数;*R_j*—每个实验中第 *i* 个分类器的平均识别率排名。

为了获得可靠的统计结果,笔者采用正常、内圈故障、外圈故障和滚珠故障的多种滚动轴承数据,进行了 30 次随机实验。

不同分类器的识别结果如表 4 所示。

表 4 不同分类器的识别率 (%)

序号	MBSMM	SGMM	SSMM	MSMM
1	98.75	95.50	96.92	92.58
2	98.83	95.58	96.58	94.17
3	98.33	96.17	95.42	93.83
4	99.17	94.42	97.75	93.83
5	98.42	95.50	96.17	92.58
6	98.33	95.58	97.42	94.00
7	97.92	96.42	96.17	92.58
8	98.75	95.50	96.92	93.58
9	98.83	95.33	96.92	94.17
10	98.42	96.17	95.50	93.83
11	98.58	95.50	96.42	93.50
12	98.83	96.17	96.58	94.17
13	98.58	96.92	95.42	94.00
14	98.75	95.33	96.92	93.50
15	98.33	96.58	95.58	93.83
16	98.33	96.17	97.42	94.00
17	99.00	96.42	95.92	92.97
18	98.75	95.42	97.42	93.50
19	99.00	95.92	96.58	94.17
20	98.83	95.33	96.58	94.00

续表

序号	MBSMM	SGMM	SSMM	MSMM
21	98.75	95.92	96.58	92.58
22	98.33	96.17	96.42	94.17
23	98.75	96.42	96.58	93.83
24	99.00	95.92	95.42	93.83
25	98.58	96.42	96.92	92.58
26	98.33	96.42	95.33	94.00
27	98.75	96.17	96.17	92.58
28	98.17	95.33	96.92	93.50
29	99.00	95.50	96.42	94.17
30	98.58	96.42	95.92	93.50

从表 4 可以看出:MBSMM、SGMM、SSMM 和 MSMM 的平均排名分别为 1、2.666 7、2.3 和 4;当 $\alpha = 0.05, k = 4, N = 30$ 时, $F(4, 30)$ 的临界值为 2.69。

按式(11, 12)计算,可以得到 $\chi_F^2 = 79.22$ 和 $F = 213.115$ 。因此,原始的假设被否定。根据 Nemenyi 检验, $\alpha = 0.05$ 的临界值表示如下^[16]:

$$CD = q_\alpha \sqrt{\frac{k(k+1)}{6N}} \quad (13)$$

式中: q_α —Nemenyi 试验的临界值。

根据 Nemenyi 测试表, $q_\alpha = 2.459 0$ 。

MBSMM 与其他 3 种分类方法的差值分别是 (SGMM-MBSMM, 2.666 7-1)、(SSMM-MBSMM, 2.3-1) 和 (MSMM-MBSMM, 4-1)。通过比较 SGMM-MBSMM、SSMM-MBSMM、MSMM-MBSMM 和 $CD = 0.763 7$,可以看出,MBSMM 的分类性能明显优于 SGMM、SSMM 和 MSMM 方法。

综上所述,通过比较 5 种方法的识别率、时间、kappa、准确率、召回率和 F1 得分,以及统计检验,证明笔者提出的 SRMM 方法在整体性能上明显优于其他分类方法。

虽然其他方法也显示出优越的性能,但与 SRMM 方法相比,它们的性能明显不足。

4 结束语

笔者利用非平行超平面、矩阵结构多元性等思想提出了一种基于多分类边界支持矩阵机(MBSMM)的滚动轴承故障诊断方法。

通过对所提方法的分析与比较,可以得出结论如下:

(1)所提方法通过建立多分类目标函数,利用非平行边界超平面来隔离任意两种类型的数据,非平行边界超平面可以最大化任意两类样本之间的间隔,达到预期的分类效果;

(2)在 MBSMM 中引入 SOR 算法,SOR 可以线性收敛到最优值,不需要太多计算就可以处理大规模数据集,大大提高了算法的计算效率;

(3)将 MBSMM 应用于滚动轴承故障诊断中,其在 κ 、准确率、召回率和 F1 得分等衡量指标下均表现出优越性。

虽然所提方法在滚动轴承故障诊断中表现出优异的分类性能,但是其仍然存在一些问题需要进一步完善,如变工况、样本不平衡等状态下的模型建立和分类问题。

在接下来的研究中,课题组将根据变工况数据的特征和样本间的权重,继续对该问题做进一步的研究。

参考文献 (References):

[1] 张 辉,张 超,辛 阔,等.基于 FDM 和 TEO 的滚动轴承故障诊断研究[J].机电工程,2021,38(7):850-856.

[2] HAN Bao-kun, JI Shan-shan, WANG Jin-rui, et al. An intelligent diagnosis framework for roller bearing fault under speed fluctuation condition [J]. *Neurocomputing*, 2021, 420:171-180.

[3] 李道军,李廷锋,刘德平.基于 LMD 与改进 SVM 的轴承故障诊断方法[J].机械制造,2021,59(6):5.

[4] 梁治华,曹江涛,姬晓飞.基于 EEMD 和 CS-SVM 的滚动轴承故障诊断研究[J].机电工程,2019,36(6):622-627.

[5] 王怀光,张培林,李 胜,等.量子 BP 神经网络的自适应振动信号压缩及应用[J].振动与冲击,2014,33(19):35-39.

[6] LEE S. Monte Carlo simulation using support vector machine and kernel density for failure probability estimation[J]. *Reliability Engineering & System Safety*, 2021, 209: 107481.

[7] HANG Wen-long, FENG Wei, LIANG Shuang, et al. Deep stacked support matrix machine based representation learning for motor imagery EEG classification[J]. *Computer Methods and Programs in Biomedicine*, 2020, 193:105466.

[8] LUO Luo, XIE Yu-bo, ZHANG Zhi-hua, et al. Support matrix machines [J]. *Proceedings of the 32nd International Conference on Machine Learning (ICML)*, 2015:938-947.

[9] ZHENG Qing-qing, ZHU Feng-yuan, QIN Jing, et al. Multiclass support matrix machine for single trial EEG classification[J]. *Neurocomputing*, 2018, 275:869-880.

[10] ZHENG Qing-qing, ZHU Feng-yuan, QIN, et al. Sparse support matrix machine [J]. *Pattern Recognition*, 2018, 76:715-726.

[11] PAN Hai-yang, YANG Yu, ZHENG Jin-de, et al. A fault diagnosis approach for roller bearing based on symplectic geometry matrix machine [J]. *Mechanism and Machine Theory*, 2019, 140:31-43.

[12] PAN Xian-li, PANG Xin-ying, WANG Hong-mei, et al. A safe screening based framework for support vector regression[J]. *Neurocomputing*, 2018, 287:163-172.

[13] PAN Hai-yang, ZHENG Jin-de. An intelligent fault diagnosis method for roller bearing using symplectic hyperdisk matrix machine[J]. *Applied Soft Computing*, 2021, 105: 107284.

[14] CHENG Zheng-yang, WANG Rong-ji. Deep stacking H-norm center configuration convex hull and its application in fault diagnosis of rolling bearing[J]. *Mechanism and Machine Theory*, 2020, 143:103648.

[15] KUNCHEVAL L I, RODRIGUEZ J J. Classifier ensembles with a random linear oracle [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2007, 19(4):500-508.

[16] GANAIE M A, TANVEER M. LSTSVM classifier with enhanced features from pre-trained functional link network [J]. *Applied Soft Computing*, 2020, 93:106305.

[编辑:雷 敏]

本文引用格式:

马文静,李 鑫,张 云.多分类边界支持矩阵机及其在滚动轴承故障诊断中的应用[J].机电工程,2022,39(1):65-70.

MA Wen-jing, LI Xin, ZHANG Yun. Multi-class bounded support matrix machine and its application in rolling bearing fault diagnosis[J]. *Journal of Mechanical & Electrical Engineering*, 2022, 39(1):65-70.

《机电工程》杂志: <http://www.meem.com.cn>