

# 控制与决策

Control and Decision

## $l_p$ -范数约束下MKL-OC-ELM的装备故障检测

刘星, 赵建印, 朱敏, 张伟

引用本文:

刘星, 赵建印, 朱敏, 等.  $l_p$ -范数约束下MKL-OC-ELM的装备故障检测[J]. 控制与决策, 2021, 36(10): 2379–2388.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.0443>

## 您可能感兴趣的其他文章

Articles you may be interested in

### 基于局部信息增量与MPLS的质量相关故障检测方法

Quality-related fault detection method based on local information increment and MPLS  
控制与决策. 2021, 36(7): 1647–1654 <https://doi.org/10.13195/j.kzyjc.2019.1402>

### 输入约束不确定系统的点对点迭代学习控制与优化

Point-to-point iterative learning control and optimization for uncertain systems with constrained input  
控制与决策. 2021, 36(6): 1435–1441 <https://doi.org/10.13195/j.kzyjc.2019.0908>

### 基于FWADE-ELM的短时交通流预测方法

Short-term traffic flow forecasting based on hybrid FWADE-ELM  
控制与决策. 2021, 36(4): 925–932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

### 基于FWADE-ELM的短时交通流预测方法

Short-term traffic flow forecasting based on hybrid FWADE-ELM  
控制与决策. 2021, 36(4): 925–932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

### 事件触发机制下分布时滞网络化控制系统 $H_\infty$ 故障检测

Event-triggered  $H_\infty$  fault detection for networked control systems with distributed delays  
控制与决策. 2020, 35(12): 3059–3065 <https://doi.org/10.13195/j.kzyjc.2019.0456>

# $l_p$ -范数约束下MKL-OC-ELM的装备故障检测

刘星<sup>1†</sup>, 赵建印<sup>1</sup>, 朱敏<sup>2</sup>, 张伟<sup>3</sup>

(1. 海军航空大学, 山东 烟台 264001; 2. 中国人民解放军91576部队, 浙江 宁波 315020;  
3. 海装西安局驻咸阳地区军事代表室, 陕西 咸阳 713100)

**摘要:** 针对列装时间短的现役装备故障样本匮乏、现有算法故障检测准确率较低的问题, 将多核学习 (multiple kernel learning, MKL) 与一类超限学习机 (OC-ELM) 相结合, 提出  $l_p$ -范数约束下多核学习一类超限学习机 ( $l_p$ -MKOCELM) 的检测模型. 在  $l_p$ -范数约束下, 定义了将MKL与OC-ELM相结合的数学优化形式, 推导出基核组合权重与Lagrange乘子的更新方式; 为方便故障检测的实施, 基于  $l_p$ -MKOCELM 定义了统计检验量与检测阈值; 通过实验验证了不同范数的约束形式的近似等价性. 将所提出方法应用于常用的UCI数据集和某型装备的测试数据, 实验结果表明, 相比于传统的SVDD、PCA、OC-SVM、OC-KELM等方法, 所提出方法在平衡漏警、虚警的同时, 能够显著提升检测精度.

**关键词:** 超限学习机; 多核学习; 一类分类; 故障检测;  $l_p$ -范数约束

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.0443

开放科学(资源服务)标识码(OSID):



**引用格式:** 刘星, 赵建印, 朱敏, 等.  $l_p$ -范数约束下MKL-OC-ELM的装备故障检测[J]. 控制与决策, 2021, 36(10): 2379-2388.

## MKL and OC-ELM fault detection based on $l_p$ -norm constraint

LIU Xing<sup>1†</sup>, ZHAO Jian-yin<sup>1</sup>, ZHU Min<sup>2</sup>, ZHANG Wei<sup>3</sup>

(1. Naval Aviation University, Yantai 264001, China; 2. Unit 91576 of the PLA Troops, Ningbo 315020, China;  
3. Military Representative Office of Naval Equipment Department in Xianyang, Xianyang 713100, China)

**Abstract:** Aiming at the problems of the shortage of fault samples for active new equipment and the low accuracy of existing algorithms for fault detection, the multiple kernel learning (MKL) and the one-class extreme learning machine (OC-ELM) are combined, and the  $l_p$ -norm constrained multiple kernel learning one-class ELM ( $l_p$ -MKOCELM) is proposed. Under the  $l_p$ -norm constraint, a mathematical optimization form combining the MKL and the OC-ELM is defined, and the update method of combination weights of the base kernel and Lagrange multipliers are derived. To facilitate the implementation of fault detection, the test statistic and detection threshold based on the  $l_p$ -MKOCELM are defined. The approximate equivalence of different norm constraints is confirmed through experiments. The proposed method is applied to the commonly used UCI data set and test data of an equipment. The experimental results show that, compared with the traditional SVDD, PCA, OC-SVM, and OC-KELM, the proposed method can significantly improve the detection accuracy while balancing missing alarm and false alarm.

**Keywords:** extreme learning machine; multiple kernel learning; one-class classification; fault detection;  $l_p$ -norm constraint

## 0 引言

故障检测是装备故障预测与健康管理(PHM)的关键技术之一, 是提升装备保障能力的重要环节. 随着科技的进步, 现役新型装备的故障机理愈加复杂且难以准确建立数学模型, 加上高质量的故障样本难以收集, 这对此类装备的故障检测带来了极大的挑战, 相关的故障检测方法成为研究人员关注的焦点<sup>[1]</sup>.

近年来, 支持向量机 (support vector machine, SVM) 以及通过核函数核化后的超限学习机 (kernel

extreme learning machine, KELM) 等基于核方法的智能诊断方法, 因其优越的性能在小样本的故障检测领域中得到了广泛应用. 这些故障检测方法将故障检测问题建模为二分类问题 (正常模式为一类, 各故障模式为另一类), 依托成熟的分类方法形成检测策略. 然而, 随着装备更新换代的加快, 大量装备实际服役年限较短, 部分装备还具有“长期贮存, 一次使用”的特点, 这就使得装备的测试数据呈现“正常样本数据较多, 没有或者只有极少量故障样本”的特征. 对

收稿日期: 2020-04-20; 修回日期: 2020-07-29.

<sup>†</sup>通讯作者. E-mail: xinghandeqipan@sina.com.

于上述机器学习方法而言,选择不同的核函数及相应的超参数,对检测结果的影响也很大<sup>[2]</sup>. 这些因素严重制约了上述方法在实际装备上的故障检测效果,使其难以在大范围进行推广运用<sup>[3]</sup>.

针对上述问题,最早由Moya等<sup>[4]</sup>提出的一类分类(one-class classification, OCC)方法因其仅需对正常样本数据进行学习的特点引起了越来越多的关注. 其中多数研究集中于支持向量数据描述(support vector data description, SVDD)<sup>[5-6]</sup>以及适用于一分类的支持向量机(one-class SVM, OC-SVM)<sup>[7-8]</sup>以及OC-SVM的相关扩展上(例如基于隐藏信息的OC-SVM<sup>[9]</sup>、协方差引导的OC-SVM<sup>[10]</sup>、集成OC-SVM<sup>[11]</sup>、面向多任务学习的OC-SVM<sup>[12]</sup>、模糊OC-SVM<sup>[13]</sup>). 最近,超限学习机(extreme learning machine, ELM)<sup>[14]</sup>因其通过计算得出输出层的权重矩阵而无需进行迭代,同时具备计算速度快、泛化性能强的特点使其在机器学习领域发展迅速. Leng等<sup>[15]</sup>首次将ELM扩展到OCC领域,提出了一类ELM(one-class extreme learning machine, OC-ELM)以及其核化形式(one-class kernel extreme learning machine, OC-KELM). 通过实验对比表明,OC-KELM较OC-ELM具有更加优越的特征捕捉能力,分类边界更加光滑. Dai等<sup>[16]</sup>将深度学习与OC-ELM相结合,通过采用堆叠式自编码器来有效表示高维复杂数据特征. Gautam等<sup>[17]</sup>提出了基于边界和基于重构的两种决策分类器,丰富了OC-ELM的理论成果. 然而,上述一类分类算法中,非核化方法存在自由参数过多且随机性较强的缺点,而核化方法则因受核函数及其参数选取的影响,算法的性能受到严重的制约.

多核学习(multiple kernel learning, MKL)是解决核函数及其参数选取问题的可选方案,能克服数据特征不规则、异构等缺点,与单核学习方法相比具有更强的解释性和灵活性. 本文针对现役新型装备电子设备的样本特点,以OC-KELM为基础建模框架,结合MKL较强的样本特征挖掘能力,提出 $l_p$ -范数约束下多核学习一类核超限学习机( $l_p$ -norm constrained multiple kernel learning one-class ELM,  $l_p$ -MKOCELM)模型,并通过多组常用公共数据集以及实际装备的测试数据进行实验,验证了所提出算法的适用性和有效性.

## 1 问题描述

### 1.1 ELM的一分类模型

对于训练样本仅包含一类数据的OCC相关问题,假设训练集为 $D_{Tr} = \{\mathbf{x}_i\}_{i=1}^n$ ,由正常类(normal

class)样本组成,测试集为 $D_{Te} = \{\mathbf{x}'_i\}_{i=1}^{n'}$ ,由正常类样本以及各个离群类(outlier class)样本共同组成. 其中: $\mathbf{x}_i \in \mathbf{R}^d$ 表示训练样本实例, $\mathbf{x}'_i \in \mathbf{R}^d$ 表示测试样本实例, $\mathbf{x}_i$ 的维数用 $d$ 来表示, $d \in \mathbf{R}$ . OC-ELM的本质是,基于目标类样本 $D_{Tr}$ ,利用超限学习机得到一个映射 $f(\cdot): \mathbf{R}^d \rightarrow \mathbf{R}$ ,使得 $D_{Tr}$ 中样本的映射值尽可能地趋近相同的某一非零实数值 $s$ . 文献[15]证明了 $s$ 选择任一非零数值的效果是等价的,不失一般性, $s$ 设为1,此时,面向OCC的ELM可形式化为

$$\min_{\beta, \xi} \frac{1}{2} \|\beta\|_2^2 + \frac{C}{2} \sum_{i=1}^n \xi_i^2; \quad (1)$$

s.t.  $\mathbf{h}(\mathbf{x}_i)\beta = 1 - \xi_i, i = 1, 2, \dots, n.$

其中: $\|\cdot\|_2$ 表示向量的2范数; $\beta = [\beta_1, \dots, \beta_L]^T$ 表示模型的输出权重向量; $\mathbf{h}(\mathbf{x}_i) = [h_1(\mathbf{x}_i), \dots, h_L(\mathbf{x}_i)]$ 表示隐藏层对样本 $\mathbf{x}_i$ 的映射向量; $\xi_i$ 表示对应于样本 $\mathbf{x}_i$ 的训练误差; $C$ 为模型的正则化参数,并且 $C \in \mathbf{R}^+$ . 使用KKT条件求解式(1),可得

$$\beta = \mathbf{H}^T(c^{-1}\mathbf{I} + \mathbf{H}\mathbf{H}^T)^{-1}\mathbf{e}. \quad (2)$$

其中: $\mathbf{H} = [\mathbf{h}(\mathbf{x}_1)^T, \dots, \mathbf{h}(\mathbf{x}_n)^T]^T$ ,表示输入样本的映射矩阵; $\mathbf{e}$ 为全1的列向量.

若通过Mercer条件来定义核矩阵 $\Omega = \mathbf{H}\mathbf{H}^T$ ,则 $\Omega(i, j) = \mathbf{h}(\mathbf{x}_i) \cdot \mathbf{h}(\mathbf{x}_j)^T = k(\mathbf{x}_i, \mathbf{x}_j)$ ,由此实现OC-ELM的核化,表示为如下形式:

$$f(\cdot) = \mathbf{h}(\cdot)\mathbf{H}^T(c^{-1}\mathbf{I} + \mathbf{H}\mathbf{H}^T)^{-1}\mathbf{e} = [k(\cdot, \mathbf{x}_1), \dots, k(\cdot, \mathbf{x}_n)](c^{-1}\mathbf{I} + \Omega)^{-1}\mathbf{e}. \quad (3)$$

### 1.2 MKL的一般化形式

当前, MKL大多以SVM作为基础分类器,使用不同的方法来确定核组合方式,其中最为流行的是使用有限个预先给定的基核进行线性凸组合. 令 $\{(\mathbf{x}_i, y_i)\}_{i=1}^n$ 表示一个二分类训练数据集. 其中: $\mathbf{x}_i \in \mathbf{R}^d$ 表示训练样本实例, $y_i \in \{\pm 1\}$ 表示 $\mathbf{x}_i$ 对应的样本标签. 软间隔SVM(soft-margin support vector machine, SMSVM)的优化模型可表示为

$$\min_{\mathbf{w}, b, \xi} \frac{1}{2} \langle \mathbf{w}, \mathbf{w} \rangle + C \sum_{i=1}^n \xi_i; \quad (4)$$

s.t.  $y_i(\langle \mathbf{w}, \phi(\mathbf{x}_i) \rangle + b) \geq 1 - \xi_i,$   
 $\xi_i \geq 0, i = 1, 2, \dots, n.$

其中: $\mathbf{w}$ 为分离超平面, $\xi_i$ 为松弛变量, $b$ 为偏置, $C$ 为惩罚因子.

在MKL框架下,设 $\{k_q(\cdot, \cdot)\}_{q=1}^r$ 为预定义的 $r$ 个基核, $\{\phi_q(\cdot)\}_{q=1}^r$ 表示对应于基核 $\{k_q(\cdot, \cdot)\}_{q=1}^r$ 的特征映射, $\mathbf{K}_q$ 表示在给定学习任务下基于多个基核

$k_q(\cdot, \cdot)$  构造的核矩阵. 于是多核特征映射可表示为

$$\phi(\cdot; \gamma) = [\sqrt{\gamma_1}\phi_1(\cdot, \cdot), \sqrt{\gamma_2}\phi_2(\cdot), \dots, \sqrt{\gamma_r}\phi_r(\cdot)],$$

$\mathbf{K}(\gamma) = \sum_{q=1}^r \gamma_q \mathbf{K}_q$  为组合核矩阵, 而

$$k(\mathbf{x}_i, \mathbf{x}_j; \gamma) = \langle \phi(\mathbf{x}_i; \gamma), \phi(\mathbf{x}_j; \gamma) \rangle = \sum_{q=1}^r \gamma_q k_q(\mathbf{x}_i, \mathbf{x}_j)$$

为组合核函数,  $\gamma = \{\gamma_q\}_{q=1}^r$  表示基核组合权重. 此时, 式(4)转换为

$$\begin{aligned} \min_{w, b, \xi, \gamma} \quad & \frac{1}{2} \sum_{q=1}^r \langle \mathbf{w}_q, \mathbf{w}_q \rangle + C \sum_{i=1}^n \xi_i; \\ \text{s.t.} \quad & y_i \left( \sum_{q=1}^r \langle \mathbf{w}_q, \sqrt{\gamma_q} \phi_q(\mathbf{x}_i) \rangle + b \right) \geq 1 - \xi_i, \\ & \xi_i \geq 0, \quad i = 1, 2, \dots, n, \\ & \gamma_q \geq 0, \quad q = 1, 2, \dots, r. \end{aligned} \quad (5)$$

其中, 对基核权重  $\gamma_q \geq 0$  的约束可以确保组合核函数  $k(\mathbf{x}_i, \mathbf{x}_j; \gamma)$  是正定的.

在多核学习的过程中, 通常会面临基核权重  $\gamma$  产生缩放与初始化的问题, 进而产生畸形解. 解决此类问题, 常用的做法是对  $\gamma$  施加  $l_p$ -范数约束.

## 2 $l_p$ -MKOCELM 及其优化

当使用  $l_p$ -MKOCELM 作为检测模型寻找映射函数  $f(\mathbf{x})$  时, 其初始优化问题可表示为

$$\begin{aligned} \min_{\beta, \xi, \gamma} \quad & \frac{1}{2} \sum_{q=1}^r \|\beta_q\|_2^2 + \frac{C}{2} \sum_{i=1}^n \xi_i^2; \\ \text{s.t.} \quad & \sum_{q=1}^r \sqrt{\gamma_q} \phi_q(\mathbf{x}_i) \beta_q = 1 - \xi_i, \quad i = 1, 2, \dots, n, \\ & \sum_{q=1}^r \gamma_q^p = 1, \quad \gamma_q \geq 0, \quad p > 1. \end{aligned} \quad (6)$$

其中:  $\beta = [\beta_1^T, \beta_2^T, \dots, \beta_r^T]^T$  表示模型总的输出权重,  $\beta_q \in \mathbf{R}^{|\phi_q(\cdot)|}$  表示对应于第  $q$  个基核的输出权重,  $|\phi_q(\cdot)|$  表示第  $q$  个基核导出的特征空间维数,  $p$  为范数约束形式.

令  $\tilde{\beta}_q = \sqrt{\gamma_q} \beta_q$ , 有

$$\sum_{q=1}^r \|\beta_q\|_2^2 = \sum_{q=1}^r \|\tilde{\beta}_q\|_2^2 / \gamma_q. \quad (7)$$

将式(7)代入优化问题(6), 则  $l_p$ -MKOCELM 的优化问题转化为

$$\begin{aligned} \min_{\tilde{\beta}, \xi, \gamma} \quad & \frac{1}{2} \sum_{q=1}^r \frac{1}{\gamma_q} \|\tilde{\beta}_q\|_2^2 + \frac{C}{2} \sum_{i=1}^n \xi_i^2; \\ \text{s.t.} \quad & \sum_{q=1}^r \phi_q(\mathbf{x}_i) \tilde{\beta}_q = 1 - \xi_i, \quad i = 1, 2, \dots, n, \end{aligned}$$

$$\sum_{q=1}^r \gamma_q^p = 1, \quad \gamma_q \geq 0, \quad p > 1. \quad (8)$$

用  $\tilde{\beta}_q$  取代  $\sqrt{\gamma_q} \beta_q$ , 使得式(8)成为一个关于  $\tilde{\beta}_q$  和  $\gamma$  的联合凸优化问题.

为了求解问题(8), 使用 Lagrange 乘数法来求最优解. 首先给出优化问题所对应的 Lagrange 函数

$$\begin{aligned} L_1(\tilde{\beta}_q, \xi, \gamma_q, \alpha) = & \frac{1}{2} \sum_{q=1}^r \frac{1}{\gamma_q} \|\tilde{\beta}_q\|_2^2 + \frac{C}{2} \sum_{i=1}^n \xi_i^2 - \\ & \sum_{i=1}^n \alpha_i \left( \sum_{q=1}^r \phi_q(\mathbf{x}_i) \tilde{\beta}_q - 1 + \xi_i \right) + \lambda \left( \sum_{q=1}^r \gamma_q^p - 1 \right). \end{aligned} \quad (9)$$

其中: Lagrange 乘子分别为  $\alpha$  和  $\lambda$ ,  $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_n]^T$ . 对式(9)中的优化变量  $\alpha$  和  $\lambda$  分别求偏导找极值点, 得到 KKT 优化条件, 即

$$\frac{\partial L_1(\tilde{\beta}_q, \xi, \gamma_q, \alpha)}{\partial \tilde{\beta}_q} = 0 \rightarrow \tilde{\beta}_q = \gamma_q \sum_{i=1}^n \phi_q^T(\mathbf{x}_i) \alpha_i, \quad (10)$$

$$\frac{\partial L_1(\tilde{\beta}_q, \xi, \gamma_q, \alpha)}{\partial \xi_i} = 0 \rightarrow \xi_i = \frac{1}{C} \alpha_i, \quad (11)$$

$$\frac{\partial L_1(\tilde{\beta}_q, \xi, \gamma_q, \alpha)}{\partial \alpha_i} = \sum_{q=1}^r \phi_q(\mathbf{x}_i) \tilde{\beta}_q - 1 + \xi_i = 0, \quad (12)$$

$$\frac{\partial L_1(\tilde{\beta}_q, \xi, \gamma_q, \alpha)}{\partial \gamma_q} = 0 \rightarrow \|\tilde{\beta}_q\|_2^2 = 2p\lambda\gamma_q^{p+1}. \quad (13)$$

采用两步交替优化的策略求解 Lagrange 乘子  $\alpha$ 、基核组合权重  $\gamma$ .

1) 在固定  $\gamma$  的条件下优化  $\alpha$ .

将式(10)、(11)分别代入(12)中, 得到

$$\sum_{q=1}^r \phi_q(\mathbf{x}_i) \gamma_q \sum_{i=1}^n \phi_q^T(\mathbf{x}_i) \alpha_i = 1 - \alpha_i / C. \quad (14)$$

式(14)中等号左边部分等于下面的结果:

$$\begin{aligned} & \sum_{q=1}^r \phi_q(\mathbf{x}_i) \gamma_q \sum_{i=1}^n \phi_q^T(\mathbf{x}_i) \alpha_i = \\ & \left[ \sum_{q=1}^r \gamma_q k_q(\mathbf{x}_i, \mathbf{x}_1), \dots, \sum_{q=1}^r \gamma_q k_q(\mathbf{x}_i, \mathbf{x}_n) \right] \alpha. \end{aligned} \quad (15)$$

联合式(14)和(15)可以得到  $\mathbf{K}(\gamma)\alpha = \mathbf{e} - \alpha/C$ ,  $\mathbf{e}$  表示全1的列向量. 最终得到

$$\alpha = (\mathbf{K}(\gamma) + 1/C)^{-1} \mathbf{e}. \quad (16)$$

2) 在给定  $\alpha$  的条件下更新  $\gamma$ .

根据式(13), 得到

$$\gamma_q = \left( \frac{\|\tilde{\beta}_q\|_2^2}{2p\lambda} \right)^{1/(p+1)} = \frac{\|\tilde{\beta}_q\|_2^{2/(p+1)}}{(2p\lambda)^{1/(p+1)}}. \quad (17)$$

由约束条件  $\sum_{q=1}^r \gamma_q^p = 1$  和式(13),得到

$$(2p\lambda)^{1/(p+1)} = \left( \sum_{q=1}^r \|\tilde{\beta}_q\|_2^{2p/(p+1)} \right)^{1/p}. \quad (18)$$

已知  $\|\tilde{\beta}_q\|_2^2 = \gamma_q \|\beta_q\|_2^2$ , 将其与式(18)一起代入(17),得到

$$\gamma_q^{\text{new}} = \frac{(\gamma_q \|\beta_q\|_2^2)^{1/(p+1)}}{\left[ \sum_{q=1}^r (\gamma_q \|\beta_q\|_2^2)^{p/(p+1)} \right]^{1/p}}. \quad (19)$$

其中:  $\gamma_q^{\text{new}}$  表示 MKL 中第  $q$  个基核在本次迭代更新后的权值,  $\gamma_q$  表示 MKL 中第  $q$  个基核在前一次迭代中的权值. 根据式(10)推导可以得到  $\beta_q = \gamma_q [\phi_q^T(\mathbf{x}_1), \phi_q^T(\mathbf{x}_2), \dots, \phi_q^T(\mathbf{x}_n)] \alpha$ , 再根据  $\|\tilde{\beta}_q\|_2^2 = \gamma_q \|\beta_q\|_2^2$ , 进一步推导得到  $\beta_q = \sqrt{\gamma_q} \sum_{i=1}^n \alpha_i \phi_q^T(\mathbf{x}_i)$ , 因此,有

$$\|\beta_q\|_2^2 = \gamma_q \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j k_q(\mathbf{x}_i, \mathbf{x}_j). \quad (20)$$

将式(20)代入(19),新的基核权重  $\gamma_q^{\text{new}}$  得到更新, 在  $\gamma_q$  的初始值非负时, 每次迭代后的结果都保持非负, 因此, 在式(8)的约束条件中可以省去对  $\gamma_q$  的非负约束.

通过上述交替优化过程, 当得到最优的模型参数  $\alpha^*$  和  $\gamma^*$  时, 决策函数表示为

$$f(\cdot) = \sum_{i=1}^n (\alpha_i^*)^T \sum_{q=1}^r \gamma_q^* k_q(\mathbf{x}_i, \cdot). \quad (21)$$

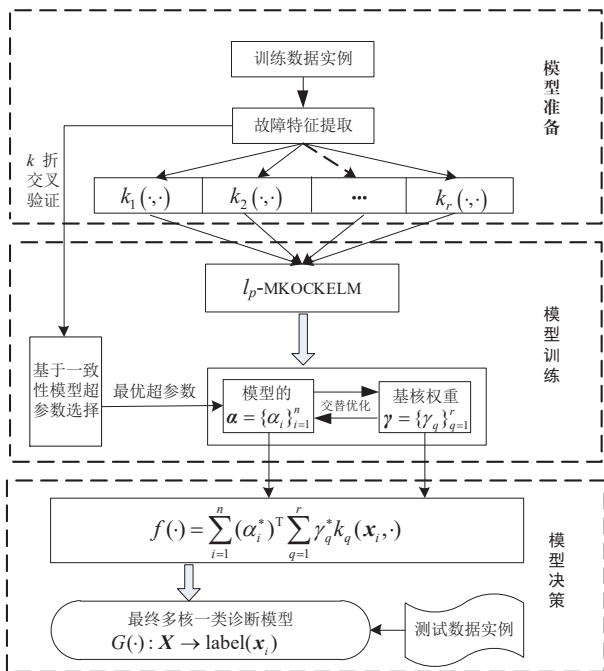


图1  $l_p$ -MKOCELM检测模型的一般框架

依据上述讨论,  $l_p$ -MKOCELM的基本框架如图1所示.

### 3 基于 $l_p$ -MKOCELM 的故障检测

根据  $l_p$ -MKOCELM 的特点, 将数据集进行改造, 目标类样本(正常样本)由正常工作状态下的指标向量构成, 离群类样本(异常样本)则由各类故障状态下的指标向量构成, 可使用  $l_p$ -MKOCELM 模型进行故障检测.

#### 3.1 统计检测量和检测阈值

与传统的检测方法类似, 在使用  $l_p$ -MKOCELM 进行故障检测前, 需要分别对统计检测量以及检测阈值参数预先进行设定. 对于测试样本, 统计检测量为

$$F(z) = \left| \sum_{j=1}^n \sum_{q=1}^r \gamma_q k_q(z, \mathbf{x}_j) \alpha_j - 1 \right|. \quad (22)$$

在  $l_p$ -MKOCELM 模型的训练阶段, 考虑到奇异点的存在, 训练样本并不会被全部划分为目标样本. 通常的做法是允许一小部分被错误划分, 即小部分正常样本被分类为故障样本, 这个比例简称为拒绝比例, 记为  $v$ . 不失一般性, 假设训练集中各样本的统计检验量排序为  $F_1 \geq F_2 \geq \dots \geq F_N$ , 则模型的检测阈值定义为  $\theta = F_{\text{floor}(N \times v)}$ , 其中  $\text{floor}(\alpha)$  表示不大于  $\alpha$  的最大值. 定义  $o_{\mathbf{x}'_j}$  为  $l_p$ -MKOCELM 针对样本  $\mathbf{x}'_j$  的输出.

$l_p$ -MKOCELM 模型对样本的类别判定准则如下:

$$y'_j = \text{label}(\mathbf{x}'_j) = \begin{cases} \text{正常样本, } o_{\mathbf{x}'_j} < \theta; \\ \text{故障样本, } o_{\mathbf{x}'_j} \geq \theta. \end{cases}$$

#### 3.2 $l_p$ -MKOCELM 模型超参数选择

为了使分类器能够创建适当的分类边界, 在模型训练中要选择最佳的超参数(本文需要优化的超参数是正则化参数  $C$ ), 最小化交叉验证分类误差方法被当前各类机器学习方法普遍采用. 由于  $l_p$ -MKOCELM 的训练集中只有目标类样本, 该方法不再适用. 本文采用基于一致性的模型优化方法来选择模型超参数<sup>[18]</sup>, 具体选择步骤如下:

1) 将整体数据集按  $k$  折交叉验证划分, 分为两类数据集: 训练集、测试集.

2) 求出估计误差的阈值

$$\hat{\epsilon}_{\text{thr}} = v + \sqrt{\frac{v(1-v)}{M}}. \quad (23)$$

其中:  $v$  为模型预先给定的拒绝比例,  $M$  为测试集的规模.

3) 使用  $k$  折交叉验证方法, 求出模型在数据集上

的平均检测错误率,用  $\bar{\varepsilon}_C$  来表示.

4) 预先提供适当的超参数预选范围,将超参数集合降序排列(降序排列依据:各超参数所对应模型的复杂度).令超参数排列为  $\{C_k^{\max}, \dots, C_k^{\min}\}$ ,  $C_k^i$  表示降序集合中某个模型复杂度所对应的超参数.遍历该降序集合,当某个  $C_k^i$  所对应的  $\bar{\varepsilon}_C$  大于  $\hat{\varepsilon}_{\text{thr}}$  时,此时的  $C_k^i$  被认为与  $v$  相一致,  $C_k^i$  就是模型的最优超参数;然后  $C_k^i$  将被传递给模型训练阶段.

### 3.3 $l_p$ -MKOCELM 算法

基于上述讨论,下面给出  $l_p$ -MKOCELM 算法具体步骤.

1) 给定训练集  $D_{\text{Tr}} = \{\mathbf{x}_i\}_{i=1}^n$  和测试集  $D_{\text{Te}} = \{\mathbf{x}'_i\}_{i=1}^{n'}$ , 设置基核  $\{k_q(\cdot, \cdot)\}_{q=1}^r$ 、最大迭代次数  $N$ 、交叉验证折数  $k$ 、正则化因子  $C$  的参数选择范围  $\{10^{-8}, 10^{-7}, \dots, 10^8\}$ ; 范数约束形式  $p$  取 2.

2) 输入拒绝比例  $v$ , 根据式 (23) 计算估计误差阈值  $\hat{\varepsilon}_{\text{thr}}$ , 基于一致性的模型超参数选择方法获取正则化因子  $C$ , 由式 (14) 和 (15) 计算组合核矩阵  $\mathbf{K}(\gamma)$ .

3)  $|\Delta|$  表示  $l_p$ -MKOCELM 模型中包含的基核个数, 令  $h = 1$ ,  $\gamma^h = [1/|\Delta|, \dots, 1/|\Delta|]$ .

4) while  $h \leq N$

根据  $\mathbf{K}(\gamma)$  及  $C$ , 由式 (16) 计算  $l_p$ -MKOCELM 模型的  $\mathbf{a}$ ;

根据式 (19) 更新  $\gamma_u^h \rightarrow \gamma_u^{h+1}$ ;

根据式 (20) 计算  $\|\beta_q\|_2^2$ ;

if  $\max\{|\gamma_u^{h+1} - \gamma_u^h|\} \leq 1 \times 10^{-3}$

根据式 (21) 计算决策函数  $f(\cdot)$ ;

else

令  $h = h + 1$ ;

end

end.

5) 输入测试样本  $D_{\text{Te}}\{\mathbf{x}'_j\}_{j=1}^{n'}$ , 得到  $\mathbf{x}'_j$  所对应的状态.

### 3.4 模型检测效能评价

混淆矩阵是直观评价分类器性能的基础工具<sup>[19-20]</sup>, 表 1 给出了二分类问题中的混淆矩阵.

表 1 混淆矩阵

真实情况	分类结果	
	正例	反例
正例	TP(真阳性)	FN(假阴性)
反例	FP(假阳性)	TN(真阴性)

基于表 1, 可以得到如下常用于衡量不平衡二分类问题的性能指标:

$$1) \text{ precision} = \text{TP}/(\text{TP} + \text{FP});$$

$$2) \text{ recall or sensitivity} = \text{TP}/(\text{TP} + \text{FN});$$

$$3) \text{ specificity} = \text{TN}/(\text{TN} + \text{FP});$$

$$4) \text{ F1} = \frac{2 \times \text{precision} \times \text{recall}}{\text{precision} + \text{recall}};$$

$$5) \text{ G-mean} = \sqrt{\text{precision} \times \text{recall}};$$

$$6) \text{ accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}};$$

$$7) \text{ AUC} = 0.5 \times (\text{sensitivity} + \text{specificity}).$$

F1 分数、曲线下方面积 (AUC) 和  $G$ -mean 是统计学中衡量二分类模型精确度的重要指标, 近些年来, 这些指标又被推广到一分类领域.

考虑到在特定的故障检测事例中, 决策阈值通常是准确的单一数值, 在此情况下, ROC 曲线发生退化, 仅由 (0, 0)、(1-specificity, sensitivity) 和 (1, 1) 三点构成, 因此, 这里的曲线下方面积 (area under curve, AUC) 计算公式并不能如传统 AUC 那样全面衡量分类器的综合性能. 同时由于样本数据存在类不平衡性, 仅仅通过常规的检测准确率 (accuracy) 无法全面评估检测模型的效能.

本文采用 F1 分数和  $G$ -mean 作为主要评标, 而将 AUC、accuracy 作为辅助指标对模型的性能进行评估<sup>[21]</sup>.

## 4 仿真实验

为客观验证  $l_p$ -MKOCELM 模型的检测性能, 实验选用主流的一分类算法 SVDD<sup>[5]</sup>、PCA<sup>[18]</sup>、OC-SVM<sup>[6]</sup> 以及近年来流行的 OC-KELM<sup>[17]</sup> 进行对比验证. 其中: SVDD 算法和 PCA 算法通过调用文献 [18] 所提出并设计开发的 dd\_tools 工具箱来实现; OC-SVM 算法通过调用台湾大学林智仁教授等开发设计的 libsvm 工具箱实现; OC-KELM 算法通过调用 R.P.W. Duin 开发的模式识别和单类分类器工具箱实现. 在每个实验之前, 均对数据进行了 Z-score 标准化.

实验中, OC-KELM 和  $l_p$ -MKOCELM 算法的正则化参数的取值范围均为  $\{10^{-8}, 10^{-7}, \dots, 10^7, 10^8\}$ ;  $l_p$ -范数取值为 2; PCA 中的主元数量选择范围从 2 到 7, 变化步长设为 1; 核参数的相关设置参见文献 [17]. SVDD、OC-SVM 以及 OC-KELM 均选取 RBF 核, 核参数选取范围为: 首先计算训练集中各样本对的最小 2 范数与最大 2 范数, 以此为上下边界; 然后等间隔取 20 个离散值, 作为核参数待选集合. 所提出方法的核函数设置情况详见相关实验. 以上算法实验均在 Windows 10(64 位) 环境中的 Matlab 2017b 上运

行, 仿真硬件配置为: Inter Core i7-8550 CPU, 主频为 3.10 GHz 及 16 GB RAM.

4.1 UCI 公共数据集实验

采用 UCI 数据库(目前机器学习领域中使用最广泛的公开数据库之一)中的 6 个分类数据集进行仿真实验, 相关描述如表 2 所示. 参考文献 [20] 中的设置: 基核设置为 12 个, 分别为 1 个线性核、3 个多项式核和 8 个高斯核(以训练样本对的平均 2 范数作为核参数). 每次随机抽取正常类样本的 1/2 组成一个集合, 作为训练样本集; 而测试样本集则由抽取后剩余的 1/2 正常样本与异常类样本共同组成, 实验重复 21 次. 首次运行仿真实验时, 拒绝比例  $v$  设置为 0.1, 折数

$k$  设置为 5, 采用基于一致性的模型超参数选择方法选取合适的正则化参数  $C$ , 并将该参数直接运用于之后的 20 次实验中. 表 3 记录了 20 次实验结果的平均值以及相应的模型参数.

表 2 UCI 实验数据集描述

数据集名称	特征数	目标类数	异常类数	目标类名称
Ecoli	7	52	284	periplasm
Sonar	60	111	97	mines
Diabetese	8	500	268	present
Liver	6	145	200	healthy
Spectf	44	55	212	0
Abalone	8	1407	2770	classes 1 ~ 8

表 3 一类分类器在 UCI 数据集的实验结果

数据集	方法	F1	AUC	G-mean	accuracy	训练时间 /s	测试时间 /s	参数取值
Ecoli	SVDD	0.4471	0.6186	0.6249	0.8181	0.8765	0.5203	$\sigma = 5.5123$
	PCA	0.4329	0.5202	0.4827	0.7653	0.7536	0.5128	$n = 3$
	OC-SVM	0.4607	0.5317	0.5902	0.8175	—	—	$\gamma = 0.0512$
	OC-KELM	0.5928	0.6304	0.7452	0.8116	0.8585	0.5986	$C = 1, \sigma = 3.1221$
	$l_p$ -MKOCELM	0.8593	0.8929	0.8604	0.9281	1.0585	0.6697	$C = 0.01$
Sonar	SVDD	0.5943	0.5736	0.6010	0.5606	0.2165	0.2296	$\sigma = 13.435$
	PCA	0.5291	0.5301	0.5913	0.4811	0.1786	0.1239	$n = 3$
	OC-SVM	0.5912	0.6001	0.5601	0.5813	—	—	$\gamma = 0.0152$
	OC-KELM	0.5612	0.4911	0.5426	0.3715	0.2878	0.1579	$C = 0.1, \sigma = 6.6293$
	$l_p$ -MKOCELM	0.6353	0.8167	0.6389	0.8956	0.7165	0.2321	$C = 1$
Diabetes	SVDD	0.6611	0.6627	0.5617	0.5424	1.7542	0.9468	$\sigma = 3.4144$
	PCA	0.6021	0.5435	0.6052	0.5196	1.3865	0.6397	$n = 6$
	OC-SVM	0.6013	0.5221	0.6171	0.5543	—	—	$\gamma = 0.0056$
	OC-KELM	0.6281	0.6612	0.6541	0.5447	1.9764	0.6238	$C = 0.1, \sigma = 2.2492$
	$l_p$ -MKOCELM	0.6813	0.5911	0.7074	0.5792	3.4683	1.2876	$C = 0.01$
Liver	SVDD	0.4145	0.5276	0.4741	0.3348	0.8756	0.9869	$\sigma = 2.1125$
	PCA	0.4357	0.5406	0.4872	0.3589	0.6575	0.4895	$n = 5$
	OC-SVM	0.4228	0.5298	0.4912	0.3797	—	—	$\gamma = 0.0326$
	OC-KELM	0.4257	0.5298	0.4768	0.3652	0.4264	0.7854	$C = 0.1, \sigma = 3.8123$
	$l_p$ -MKOCELM	0.4416	0.5486	0.5271	0.3733	2.1399	1.0269	$C = 10$
Spectf	SVDD	0.3667	0.7765	0.4847	0.6326	0.3108	0.3756	$\sigma = 6.2352$
	PCA	0.3658	0.7784	0.4998	0.7261	0.3793	0.3459	$n = 3$
	OC-SVM	0.3752	0.7965	0.4781	0.7368	—	—	$\gamma = 0.0327$
	OC-KELM	0.3957	0.7657	0.4138	0.6864	0.5223	0.3789	$C = 0.01, \sigma = 8.2669$
	$l_p$ -MKOCELM	0.4632	0.7968	0.5134	0.7831	1.1661	0.4397	$C = 10$
Abalone	SVDD	0.4657	0.5128	0.4237	0.5957	3.9812	1.4895	$\sigma = 1.3418$
	PCA	0.4668	0.5248	0.5928	0.5658	3.2466	1.7854	$n = 7$
	OC-SVM	0.4885	0.5451	0.5309	0.5758	—	—	$\gamma = 0.0321$
	OC-KELM	0.4069	0.5684	0.5625	0.5706	5.3491	1.5697	$C = 1, \sigma = 2.7853$
	$l_p$ -MKOCELM	0.5281	0.5772	0.7565	0.6792	9.6569	2.4687	$C = 10^{-5}$

注: OC-SVM 采用的编码方法与其他方法不同, 时间开销上没有可比性.

由表3可知:

1) 从两项主要指标 F1 和  $G$ -mean 的检测结果看,  $l_p$ -MKOCELM 模型的检测性能均优于其他模型. 以 Ecoli 数据集为例, 本文所提出方法与 SVDD、PCA、OC-SVM、OC-KELM 四种方法相比较, F1 分别提高了 92.19%、98.50%、86.52%、44.96%;  $G$ -mean 分别提高了 37.69%、78.2%、45.78%、15.46%. 这表明所提出方法具有较好的检测性能, 并且能够很好地适应具有不同类不平衡性的数据集.

2) 从两项辅助性指标 AUC 和 accuracy 来分析,  $l_p$ -MKOCELM 模型的检测性能与其他模型相比较, 绝大多数情况下都表现出一定的优越性. 以 Ecoli 数据集为例, 本文方法与 SVDD、PCA、OC-SVM、OC-KELM 四种方法相比较, AUC 分别提高了 44.34%、71.65%、67.93%、41.64%; accuracy 分别提高了 13.45%、21.27%、13.53%、14.35%. 但是对于 Diabetes 数据集, AUC 的最高值出现于 SVDD 算法; 对于 Liver 数据集, accuracy 的最高值由 OC-SVM 算法取得. 本文在 3.4 节中对此进行了解释, 辅助指标的优劣不能全面反映模型的检测性能. 各 UCI 数据集的实验结果同时也表明, 数据集的自身特性会对算法性能产生重要的影响. 在模型采用不同的数据集时, 算法性能提高的幅度存在差异. 4 项指标综合在一起, 验证了  $l_p$ -MKOCELM 模型的整体优越性.

3) 本文同时选择某项指标的最大占比来定量衡量该项指标在多个数据集上的整体性能, 采用文献 [20] 的做法, 以 F1 为例, 其最大指标占比 (percentage of the maximum F1, PMF) 定义为

$$PMF = \frac{(F1)_{ij}}{\max(F1)_{i*}} \quad (24)$$

其中:  $j$  算法对第  $i$  个数据集的 F1 值表示为  $(F1)_{ij}$ , 全体算法对于第  $i$  个数据集的 F1 的最大值则用  $\max(F1)_{i*}$  来表示. PMF 越大, 其所对应的算法在多个数据集上的综合检测性能越强. 同理, 令 PMA、PMG 和 PMAC 分别表示 AUC、 $G$ -mean 和 accuracy 的最大指标占比. 根据表 3 的实验结果, 依据最大指标占比的定义, 计算得出所有算法对各个 UCI 数据集的各检测指标均值和 PMF、PMA、PMG 以及 PMAC. 各指标均值绘于图 2, 最大指标占比按升序排列后绘于图 3.

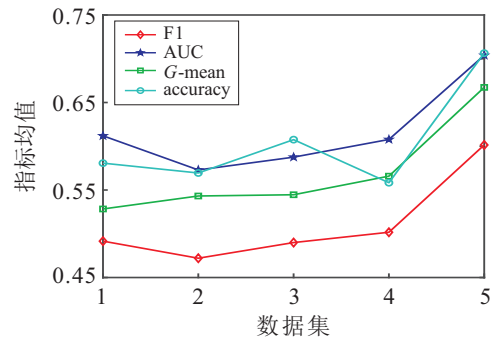

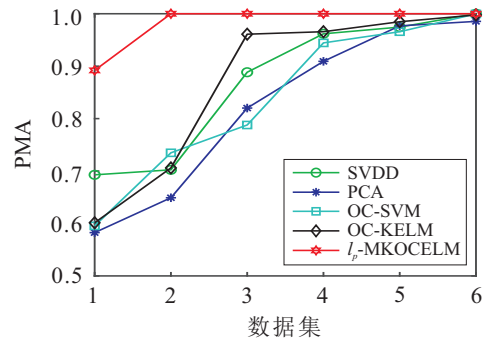



图 2 各算法在数据集上的指标均值



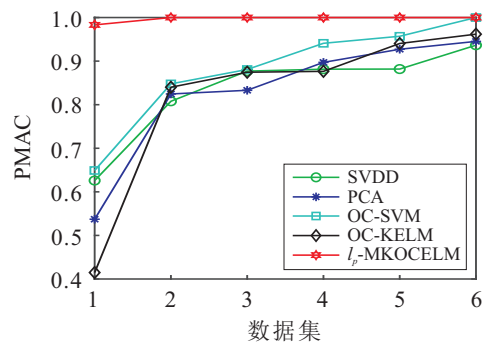
(a) F1 最大指标占比



(b) AUC 最大指标占比



(c) G-mean 最大指标占比



(d) accuracy 最大指标占比

图 3 各算法在数据集上的最大指标占比

从指标均值和各指标的最大指标占比来看,  $l_p$ -MKOCELM 模型的检测结果均为最优结果, 这表明本文方法相对于其他4种方法具有明显优势. 究其原因, 多核优化的加入使得模型可以依据数据集自身的特点挖掘不同的核函数特性, 赋予各个基核更为合理的权重, 使分类器以综合性能较优的组合核函数来创建决策边界, 从而有效提升了故障检测的精度.

4) 对于时间的开销, 由于  $l_p$ -MKOCELM 要求解多核优化问题, 训练阶段的时间较其他方法都长, 测试阶段所花费的时间与其他方法大致相当. 对于离线检测, 牺牲少量的时间开销, 换取检测精度的提升是可以接受的. 此外, 由于装备的更新周期较短, 服役期内所要进行的故障检测基本上是在小样本的基础上进行的, 时间上的开销并不会显著提高, 适合本领域的故障检测.

### 4.2 旋转变压器激励发生电路故障检测实例

旋转变压器激励发生电路是变压器的重要组成部分, 其各组件构成如图4所示, 该电路模块主要包括正弦信号产生单元、电源单元、频率控制单元、幅值调理及驱动能力调节单元. 它的主要作用是产生旋转变压器输入绕组所需的具有一定频率和幅值的正弦信号, 在提供运行激励给旋转变压器的同时, 满足永磁同步电机等系统需求.

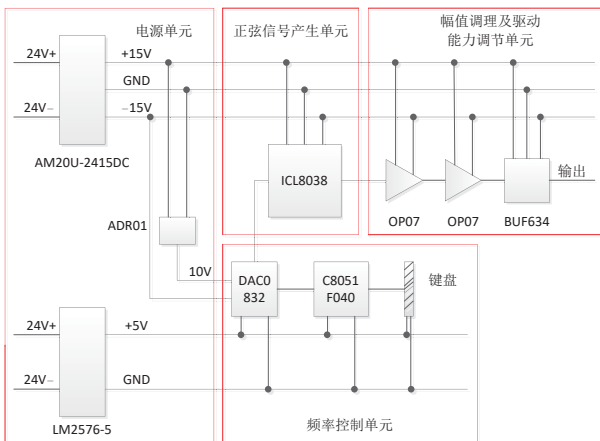


图4 旋转变压器激励发生模块原理

自动检测设备 (ATS) 对旋转变压器激励发生模块进行测试时主要涉及9个测试项目, 分别为: +15V 电源电压值、+5V 电源电压值、信号频率、信号幅值、正弦模块输入电压值、-15V 电源电压值、+10V 电源电压值、信号频率稳定性和电路板工作温度. ATS 设备共采集到正常工作状态的260组指标值, 各种故障状态下的31组指标值. 将采集到的正常工作状态的260组指标值随机选择1/2作为训练样本, 其余1/2目标类样本与31组离群类样本合并在一起共同构成

测试集.

多核设置为: 1个线性核、3个多项式核和8个高斯核(在训练样本间的最大欧氏距离与最小欧氏距离间等间隔取8个离散值作为核参数), 运用  $l_p$ -MKOCELM 进行故障检测, 实验重复20次. 按照第3.3节的步骤4) 执行迭代更新过程,  $l_p$ -MKOCELM 的学习曲线如图5所示. 可以看到, 目标值在较短的迭代步数内即可达到收敛状态.




图5  $l_p$ -MKOCELM 的学习迭代曲线

图6为  $l_p$ -MKOCELM 收敛后各个基核的权重. 其中: 1为线性核函数, 2~4为多项式核函数, 5~12为高斯核函数. 可以看到, 在最终的组合核中, 各个基核发挥了不同程度的作用. 将实验重复20次, 以均值的形式记录时效指标, 以均值和方差的形式记录精度指标, 实验结果见表4.




图6  $l_p$ -MKOCELM 的基核权重

从精度方面来看,  $l_p$ -MKOCELM 方法在4个指标上均展现出最高的精度值, 这表明其能够均衡地兼顾召回率、查准率以及特异度; 从稳定性方面来看,  $l_p$ -MKOCELM 和 OC-SVM 处于同一水平, 与其他方法相比较具有相当的优势; 从时效性方面来看, 在训练阶段, 基核权重与 Lagrange 乘子的寻优过程使得模型的时间开销略长于其他方法, 而对于测试阶段, 其时间花费与其他方法基本相当. 考虑离线检测对时效性要求不高, 并且图5展示的较少迭代次数确保了时间开销的可控性, 因此, 可以认为本文算法的综合性能优于其他算法.

表 4 各检测方法的指标值

方法	F1	AUC	G-mean	accuracy	平均训练时间 /s	平均测试时间 /s
SVDD	0.934 3 ± 0.010 1	0.938 4 ± 0.008 8	0.936 3 ± 0.009 4	0.940 7 ± 0.008 5	0.029 9	0.007 1
PCA	0.907 3 ± <b>0.009 3</b>	0.911 2 ± 0.008 4	0.907 4 ± 0.009 2	0.911 7 ± 0.008 1	0.071 2	0.005 3
OC-SVM	0.930 3 ± 0.020 1	0.932 5 ± 0.018 5	0.935 1 ± 0.017 1	0.937 3 ± 0.016 4	—	—
OC-KELM	0.926 3 ± 0.088 1	0.931 4 ± <b>0.007 7</b>	0.928 9 ± <b>0.008 3</b>	0.933 9 ± <b>0.007 4</b>	<b>0.002 1</b>	<b>0.001 6</b>
$l_p$ -MKOCELM	<b>0.945 0</b> ± 0.014 5	<b>0.946 5</b> ± 0.013 6	<b>0.948 0</b> ± 0.012 8	<b>0.949 9</b> ± 0.012 3	0.092 1	0.007 9

为了进一步分析范数的变化对  $l_p$ -MKOCELM 性能的影响,保持训练集和测试集不变,在 9 种范数约束条件下对旋转变压器激励发生模块的样本进行检测,表 5 和图 7 列出了相应的检测结果. 可以看到:在主要精度性能指标中,F1 值在 94.29%~94.89% 之间,G-mean 在 94.44%~94.95%,最高精度与最低精度相差分别只有 0.60% 和 0.51%;从时间开销上来看,训练阶段与测试阶段的时间开销在不同数值  $p$  范数条件下相差都很小. 这表明不同范数的约束形式对模型检测性能影响有限,实际应用时可从这些范数中任意选取.

表 5 不同范数约束对  $l_p$ -MKOCELM 检测性能影响

$p$	F1	AUC	G-mean	accuracy	训练时间 /s	测试时间 /s
4/3	0.9429	0.9459	0.9444	0.9479	0.9924	0.0172
2	0.9431	0.9461	0.9444	0.9479	0.9583	0.0212
3	0.9479	0.9505	0.9492	0.9505	0.9336	0.0215
4	0.9454	0.9482	0.9468	0.9501	0.9643	0.0193
5	0.9481	0.9506	0.9492	0.9523	0.9647	0.0179
6	0.9459	0.9485	0.9468	0.9501	0.9727	0.0187
7	0.9489	0.9508	0.9495	0.9533	0.9282	0.0159
8	0.9456	0.9485	0.9469	0.9501	0.9541	0.0199
9	0.9457	0.9481	0.9468	0.9501	0.9469	0.0186

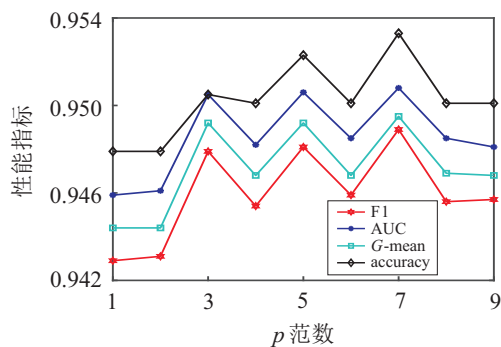


图 7  $l_p$ -MKOCELM 不同范数约束形式下的检测性能比较

### 5 结 论

针对列装时间短的现役装备故障样本匮乏、现有算法故障检测准确率较低的问题,本文以 KELM

为基本建模框架,在  $l_p$ -范数约束条件下,将多核学习与一类核超限学习机结合,提出了  $l_p$ -范数约束下的多核学习一类核超限学习机 ( $l_p$ -MKOCELM) 检测模型,以提升现役新型装备的故障检测能力. 本文的主要工作包括以下几点:

1) 基于 KELM 的建模框架,同时融入 MKL 与一类分类思想,在  $l_p$ -范数约束下实现了基核组合权重的优化,推导了统一的故障检测模型,模型建立过程具备仅需正常样本、人工干预少的优点;

2) 探讨了不同范数的约束形式对模型检测性能的影响,进一步明确了所提出方法中范数选取形式的近似等价性;

3) 将所提出方法应用于机器学习领域中常用的 6 个公共数据集和某型装备的电路故障检测中,实验结果表明:相比于 SVDD、PCA、OC-SVM、OC-KELM,本文方法适用于不同的公共数据集,并且可以有效提升实际装备的检测精度.

### 参考文献 (References)

[1] Pimentel M A F, Clifton D A, Clifton L, et al. A review of novelty detection[J]. Signal Processing, 2014, 99: 215-249.

[2] 邴其春, 龚勃文, 杨兆升, 等. 一种组合核相关向量机的短时交通流局域预测方法[J]. 哈尔滨工业大学学报, 2017, 49(3): 144-149.  
(Bing Q C, Gong B W, Yang Z S, et al. A short-term traffic flow local prediction method of combined kernel function relevance vector machine[J]. Journal of Harbin Institute of Technology, 2017, 49(3): 144-149.)

[3] 李军, 李大超. 基于优化核极限学习机的风电功率时间序列预测[J]. 物理学报, 2016, 65(13): 39-48.  
(Li J, Li D C. Wind power time series prediction using optimized kernel extreme learning machine method[J]. Acta Physica Sinica, 2016, 65(13): 39-48.)

[4] Moya M, Koch M, Hostetler L. One-class classifier networks for target recognition applications[C]. Proceedings of the World Congress on Neural Networks. Portland: International Neural Network Society, 1993:

- 797-801.
- [5] Tax D M J, Duin R P W. Support vector data description[J]. *Machine Learning*, 2004, 54(1): 45-66.
- [6] Navarro-Acosta J A, Reséndiz-Flores E O. Gompertz binary particle swarm optimization and support vector data description system for fault detection and feature selection applied in automotive pedals components[J]. *The International Journal of Advanced Manufacturing Technology*, 2017, 92(5/6/7/8): 2311-2324.
- [7] Schölkopf B, Platt J C, Shawe-Taylor J, et al. Estimating the support of a high-dimensional distribution[J]. *Neural Computation*, 2001, 13(7): 1443-1471.
- [8] 戴海发, 卞鸿巍, 马恒, 等. 基于一类SVM的综合导航系统信息故障检测方法[J]. *中国惯性技术学报*, 2017, 25(4): 555-560.  
(Dai H F, Bian H W, Ma H, et al. Information fault detection for integrated navigation systems using one-class support vector machine[J]. *Journal of Chinese Inertial Technology*, 2017, 25(4): 555-560.)
- [9] Zhu W, Zhong P. A new one-class SVM based on hidden information[J]. *Knowledge-Based Systems*, 2014, 60: 35-43.
- [10] Mefraz Khan N, Ksantini R, Shafiq Ahmad I, et al. Covariance-guided one-class support vector machine[J]. *Pattern Recognition*, 2014, 47(6): 2165-2177.
- [11] Wu R S, Chung W H. Ensemble one-class support vector machines for content-based image retrieval[J]. *Expert Systems with Applications*, 2009, 36(3): 4451-4459.
- [12] He X Y, Mourot G, Maquin D, et al. Multi-task learning with one-class SVM[J]. *Neurocomputing*, 2014, 133: 416-426.
- [13] Hao P Y. Fuzzy one-class support vector machines[J]. *Fuzzy Sets and Systems*, 2008, 167: 2317-2336.
- [14] Huang G B, Zhou H M, Ding X J, et al. Extreme learning machine for regression and multiclass classification[J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, 2012, 42(2): 513-529.
- [15] Leng Q, Qi H G, Miao J, et al. One-class classification with extreme learning machine[J]. *Mathematical Problems in Engineering*, 2015, 2015: 1-11.
- [16] Dai H Z, Cao J W, Wang T L, et al. Multilayer one-class extreme learning machine[J]. *Neural Networks*, 2019, 115: 11-22.
- [17] Gautam C, Tiwari A, Leng Q. On the construction of extreme learning machine for online and offline one-class classification—An expanded toolbox[J]. *Neurocomputing*, 2017, 261: 126-143.
- [18] Tax D M J, Muller K R. A consistency-based model selection for one-class classification[C]. *Proceedings of the 17th International Conference on Pattern Recognition*. Piscataway: IEEE, 2004: 363-366.
- [19] Iosifidis A, Mygdalis V, Tefas A, et al. One-class classification based on extreme learning and geometric class information[J]. *Neural Processing Letters*, 2017, 45(2): 577-592.
- [20] Gautam C, Balaji R, Sudharsan K, et al. Localized multiple kernel learning for anomaly detection: One-class classification[J]. *Knowledge-Based Systems*, 2019, 165: 241-252.
- [21] Tax D M J. DDtools, the data description toolbox for matlab[EB/OL]. [2013-07-24]. [http://prlab.tudelft.nl/david-tax/dd\\_tools.html](http://prlab.tudelft.nl/david-tax/dd_tools.html).

### 作者简介

刘星(1982—), 男, 助理工程师, 博士生, 从事海军航空与导弹装备管理、复杂电子系统测试与诊断技术的研究, E-mail: xinghandeqipan@sina.com;

赵建印(1976—), 男, 副教授, 博士, 从事装备可靠性与维修保障工程等研究, E-mail: 13791182798@163.com;

朱敏(1990—), 男, 工程师, 博士, 从事智能信号处理、复杂电子系统测试与诊断技术的研究, E-mail: hyzm161037@163.com;

张伟(1989—), 男, 工程师, 博士, 从事智能信号处理、复杂电子系统测试与诊断技术的研究, E-mail: hjhy1989@163.com.

(责任编辑: 李君玲)