

轮对轴承安全域增量建模方法^{*}

刘志亮^{1†} 孙文君¹ 康金龙¹ 秦勇^{2†}

(1.电子科技大学 机械与电气工程学院 成都 611731)(2.北京交通大学 轨道交通控制与安全国家重点实验室 北京 100044)

摘要 安全域是一种从域的角度描述轮对轴承可安全运行区域的定性模型.然而,高速列车运行状态的样本数据通常是正常样本,故障样本的缺乏意味着只能使用正常样本进行安全域建模.支持向量数据描述是一种单分类方法,可以只利用一类样本进行建模.现有的滚动轴承安全域建模方法基本采用的是批量学习算法,而在样本数据不断增加的情况下,批量算法的效率低下.因此,本文将增量支持向量数据描述方法引入轮对轴承的故障诊断领域,提出了一种基于样本增量学习的高速列车轮对轴承安全域的建模方法.实验结果表明,相比于传统批量学习算法,本文提出的方法在轮对轴承安全域的建模中更加高效,并且分类准确率基本不受影响.

关键词 安全域建模, 支持向量数据描述, 样本增量学习, 轮对轴承, 高速列车

DOI: 10.6052/1672-6553-2020-027

引言

高速列车是铁路运输中迅速发展起来的一种新型交通工具,具有快速性、稳定性、安全性及舒适性等优点.滚动轴承作为高速列车的关键部件之一,其工作性能的好坏直接影响列车的运行安全.然而由于滚动轴承在列车运行中起着承受和传递载荷的作用,因此,它是易损零件,故障率高.可见,准确高效的滚动轴承故障诊断对于高速列车安全运行具有重要意义.

安全域是一种从域的角度描述系统整体可安全稳定运行区域的定性模型.利用这种模型,可以通过比较安全域边界与系统运行点的相对关系分析得到系统的运行状态^[1].最早在 20 世纪 80 年代,在电力系统安全领域,Wu 等^[2]就提出了安全域分析及估计的相关理论,之后安全域理论扩展到信息安全以及轨道交通等领域.在轨道交通领域,秦勇等^[3]将安全域理论应用到列车关键设备的运行安全状态监测及评价中,提出了关于滚动轴承的安全域估计和状态辨识方法,该方法需要正常及故障样本进行安全域边界的估计.然而高速列车滚动轴承运行状态数据主要是正常的,并且获取故障样本的成本很高.因此需要研究仅使用正常运行状态的样

本数据进行安全域建模的方法.

SVDD 是 Tax 和 Duin^[4]在支持向量机^[5](support vector machine,简称 SVM)的基础上提出的一种单分类算法.与 SVM 的最优超平面不同,SVDD 旨在求解一个尽可能包容所有目标样本数据的最优超球体.考虑到 SVDD 能仅利用一类样本进行建模,而高速列车轴承又缺乏故障样本,因此本文利用 SVDD 算法对正常样本进行学习获得轴承的安全域模型,从而在故障诊断时就能对故障数据进行异常检测.

SVDD 发展至今,除了传统的批量学习算法外,还有不少学者对增量学习的 SVDD 算法进行了研究和改进.例如,刘健等^[6]提出一种基于有效向量集的 SVDD 增量学习算法—EISVDD.段修生等^[7]基于准确挖掘出样本中所有的支持向量,提出一种新的超球 SVDD 增量学习算法.花小朋等^[8]通过对原样本和新增样本进行筛选,舍弃无用样本,提出一种改进的 SVDD 增量学习算法—IISVDD.冯国瑜等^[9]针对在线学习问题,总结出一种 SVDD 增量学习方法—ISVDD.

在故障分析与诊断领域中,蒋勉等人^[10]针对转子-滑动轴承系统支承松动-碰摩故障动力学行为进行了分析,并提出基于动力学行为非线性度量的

2019-07-29 收到第 1 稿,2020-03-15 收到修改稿.

^{*} 国家重点研发计划项目(2016YFB1200401-106),国家自然科学基金资助项目(6183302)

[†] 通讯作者 E-mail:Zhiliang_Liu@uestc.edu.cn, yqin@bjtu.edu.cn

转子-轴承系统支承松动状态评估方法,韩清凯等人^[11]指出转子系统故障诊断的未来研究主要聚焦在基于大数据的智能诊断方面.而在轴承故障诊断领域,现在依然采用批量学习算法对高速列车滚动轴承进行安全域建模.在实际应用中发现,要在训练初期就收集到一个非常完整的训练集是很难实现的,更多情况下,训练样本是不断加入的.而批量学习算法在面对新加入的训练样本时,必须将新样本和原有样本组合重新进行训练,这个过程将占用大量的时间和内存,使得建模效率低下.因此用增量学习算法进行高速列车滚动轴承安全域的建模具有重要意义.

有鉴于此,本文将增量学习算法引入到轴承的故障诊断中,提出一种基于样本增量学习的高速列车滚动轴承安全域进行建模方法.该方法使用增量学习的SVDD进行轴承安全域建模,对于新加入的训练样本,可以不用舍弃之前的训练好的安全域模型,而是渐进地更新安全域边界,同时实现了仅使用正常样本建模及增量学习的目的.并且设计实验比较了批量学习的SVDD与本文方法在构造的高速列车轴承安全域模型上的差异,为高速列车滚动轴承安全域的建模方法提供了一种参考.

本文的组织结构如下.首先,第1节介绍了滚动轴承安全域的基本概念;第2节提出了基于样本增量学习的滚动轴承安全域建模方法;第3节通过实验验证本文提出方法的有效性,并与基于批量学习SVDD安全域建模方法进行比较;最后得出结论.

1 滚动轴承安全域的基本理论

在滚动轴承的故障诊断中,安全域是一种从域的角度描述滚动轴承可安全稳定运行区域的定性模型.安全域建模是指在轴承运行状态的状态特征变量所确定的空间内,通过分类方法求解得到一个安全域边界,该边界将空间分为两个区域,安全域与非安全域.一个二维空间下的安全域示意图如图1所示.

其中 x 和 y 表示两个轴承的两个状态特征变量,阴影部分表示安全域区域,阴影部分外的区域即表示非安全域区域.若轴承的状态特征变量落在安全域内,则表示其运行状态是正常的;若落在安全域以外的区域,则表示其处于故障的运行状

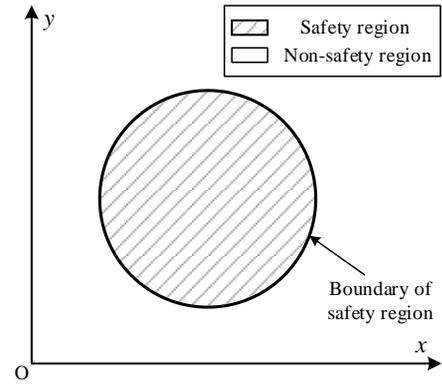


图1 安全域概念示意图

Fig.1 Schematic diagram of safety region concept

态.因此可以用安全域辨识当前轴承的运行状态是否正常.

接下来本文将增量学习SVDD应用于高速列车轴承安全域模型,详细介绍基于样本增量学习的安全域模型建立过程以及如何将建立好的安全域模型应用到轴承的故障诊断,辨识轴承运行状态的安全性.

2 基于样本增量学习的安全域建模方法

如同名称所示,SVDD是一种描述数据域的专业方法.因此,它可以用来描述轴承正常运行状态所对应的安全域.利用轴承正常数据建立的SVDD模型便可等同于安全域模型^[4,12,13].

基于样本增量学习SVDD的安全域建模方法介绍如下:

设训练样本集为 $\{\mathbf{x}_i | \mathbf{x}_i \in \mathbb{R}^n, i=1, 2, \dots, N\}$,其中 \mathbf{x}_i 是由反映轴承运行状态的特征变量所构成的向量, n 表示向量的维度, N 是训练样本个数.SVDD旨在求解包含所有训练样本的最小超球体的球心 \mathbf{a} 和半径 R ,其数学表达式为

$$\begin{aligned} \min R^2 + C \sum_i \xi_i \\ \text{s.t.} \left\| \Phi(\mathbf{x}_i) - \mathbf{a} \right\|^2 \leq R^2 + \xi_i, \xi_i > 0, \forall i = 1, 2, \dots, N \end{aligned} \quad (1)$$

其中, $\Phi(\mathbf{x}_i)$ 是 \mathbf{x}_i 经核函数在核空间中的映射, C 是惩罚参数,用以平衡 R 与松弛变量 ξ_i .

利用拉格朗日乘子法和Wolfe对偶定理^[14]可以将式(1)等价于无约束二次凸优化问题.

$$\begin{aligned} \min L = \sum_{i,j=1}^n \alpha_i \alpha_j \kappa(\mathbf{x}_i, \mathbf{x}_j) - \sum_{i=1}^n \alpha_i \kappa(\mathbf{x}_i, \mathbf{x}_i) \\ \text{s.t.} 0 \leq \alpha_i \leq C, \sum_{i=1}^n \alpha_i - 1 = 0 \end{aligned} \quad (2)$$

其中, $\kappa(\mathbf{x}_i, \mathbf{x}_j) = \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle$, 是核函数. 一般取高斯径向基函数作为核函数, 其表达式为 $\kappa(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / (2\sigma^2))$. 求解式(2)即可得到 α_i , 并且超球体半径 R 与中心 \mathbf{a} 可由 α_i 表示, 如公式(3)和公式(4)所示.

$$\mathbf{a} = \sum_i \alpha_i \Phi(\mathbf{x}_i) \quad (3)$$

$$R^2 = \|\Phi(\mathbf{x}^{sv}) - \mathbf{a}\|^2 = \kappa(\mathbf{x}^{sv}, \mathbf{x}^{sv}) - 2 \sum_i \alpha_i \kappa(\mathbf{x}^{sv}, \mathbf{x}_i) + \sum_{i,j} \alpha_i \alpha_j \kappa(\mathbf{x}_i, \mathbf{x}_j) \quad (4)$$

其中, \mathbf{x}^{sv} 是指 $0 < \alpha < C$ 对应的支持向量.

在轴承故障诊断中, 随着新样本的不断到来, 可以通过渐进地更新 α_i 的值实现增量学习, 不需要重新训练 SVDD 模型. 接下来将介绍在新样本加进来时, 如何更新 α_i 的值.

首先将式(2)转换为无约束凸规划问题, 即:

$$\min L = \sum_{i,j=1}^n \alpha_i \alpha_j \kappa(\mathbf{x}_i, \mathbf{x}_j) - \sum_{i=1}^n \alpha_i \kappa(\mathbf{x}_i, \mathbf{x}_i) + b \left(\sum_{i=1}^n \alpha_i - 1 \right) \quad (5)$$

式(5)的最优解需要满足 Kuhn-Tucker (KT) 条件, 即:

$$g_i = \frac{\partial L}{\partial \alpha_i} = 2 \sum_{j=1}^n \alpha_j \kappa(\mathbf{x}_i, \mathbf{x}_j) - \kappa(\mathbf{x}_i, \mathbf{x}_i) + b \begin{cases} \geq 0, \alpha_i = 0, (\mathbf{x}_i \in R) \\ = 0, 0 \leq \alpha_i \leq C, (\mathbf{x}_i \in S) \\ \leq 0, \alpha_i = C, (\mathbf{x}_i \in E) \end{cases} \quad (6)$$

$$\frac{\partial L}{\partial b} = \sum_{i=1}^n \alpha_i - 1 \quad (7)$$

其中, g_i 是 L 对 α_i 的偏导, 式(6)表示使 L 取到最小值的 α_i^* 值有以下三种情况, 如图2所示.

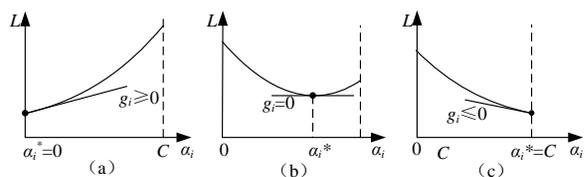


图2 α_i 取值的三种情况

Fig.2 Three cases of α_i values

(1) 若 α_i 的最优值 $\alpha_i^* = 0$, 即区间 $[0, C]$ 的左端点, $\alpha_i \in R$, 则 L 在该区间单调递增, 如图2(a);

(2) 若 α_i 的最优值 $0 < \alpha_i^* < C$, 即区间 $[0, C]$ 内, 则 L 在该区间先减后增, 如图2(b);

(3) 若 α_i 的最优值 $\alpha_i^* = C$, 即区间 $[0, C]$ 内, 则 L 在该区间单调递减, 如图2(c).

若通过已有样本求出最优解为 $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_N)$, 当有一个新样本 \mathbf{x}_c 加入时, 设新的最优解为 $\alpha^* = (\alpha_1^*, \alpha_2^*, \dots, \alpha_N^*, \alpha_c)$, 也必须满足 KT 条件, 通过调整 α_c , 并在满足 KT 条件下相应地调整其他 α_i 值, 使 α_c 也满足 KT 条件, 最后得到满足 KT 条件的最优解 α^* .

根据这个原理, 假设 $\Delta\alpha_c$ 足够小以致于不引起任意一集合 R, S 和 E 中的点变为另一集合中的点. 由式(6)可知集合 R 和 E 中的点所对应的 α_i 分别固定为 0 和 C , 其值不能改变, 否则将不满足 KT 条件, 因此可以改变值的 α_i 只能对应集合 S 中的点, 并且此类 α_i 对应的 g_i 必须固定为 0, 即其增量 Δg_i 也应为 0. 将式(6)和式(7)的等式两端写成增量形式, 得到下面两式:

$$\Delta g_i = 2 \sum_{j \in R \cup S \cup E} \Delta \alpha_j \kappa(\mathbf{x}_i, \mathbf{x}_j) + 2 \Delta \alpha_c \kappa(\mathbf{x}_i, \mathbf{x}_c) + \Delta b, \forall i \in R \cup S \cup E \quad (8)$$

$$\sum_{i \in R \cup S \cup E} \Delta \alpha_i + \Delta \alpha_c = 0 \quad (9)$$

除去不可变的 $\alpha_i (\alpha_i \in R \cup E)$, 只剩下 $\alpha_i \in S$, 且对应 $g_i = 0$, 则式(6)和式(7)可以简化为:

$$0 = 2 \sum_{j=s_1}^{s_m} \Delta \alpha_j \kappa(\mathbf{x}_i, \mathbf{x}_j) + 2 \Delta \alpha_c \kappa(\mathbf{x}_i, \mathbf{x}_c) + \Delta b, \forall i \in S \quad (10)$$

$$0 = \sum_{i=s_1}^{s_m} \Delta \alpha_i + \Delta \alpha_c \quad (11)$$

其中, s_1 为集合 S 的第一个元素的下标, s_m 为集合 S 的最后一个元素的下标.

结合式(11), 得到如下矩阵形式:

$$\begin{pmatrix} 0 & 1 & \cdots & 1 \\ 1 & 2\kappa_{s_1 s_1} & \cdots & 2\kappa_{s_1 s_m} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 2\kappa_{s_m s_1} & \cdots & 2\kappa_{s_m s_m} \end{pmatrix} \begin{pmatrix} \Delta b \\ \Delta \alpha_{s_1} \\ \vdots \\ \Delta \alpha_{s_m} \end{pmatrix} + \begin{pmatrix} 1 \\ 2\kappa_{s_1 c} \\ \vdots \\ 2\kappa_{s_m c} \end{pmatrix} \Delta \alpha_c = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \end{pmatrix} \quad (12)$$

其中, $\kappa_{s_1 s_m}$ 表示 $\kappa(\mathbf{x}_{s_1}, \mathbf{x}_{s_m})$, 其他以此类推. 记矩阵 Q 为:

$$Q = \begin{pmatrix} 0 & 1 & \cdots & 1 \\ 1 & 2\kappa_{s_1 s_1} & \cdots & 2\kappa_{s_1 s_m} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 2\kappa_{s_m s_1} & \cdots & 2\kappa_{s_m s_m} \end{pmatrix} \quad (13)$$

对式(12)做简单移项, 并令矩阵 $U = Q^{-1}$ 可得:

$$\begin{pmatrix} \Delta b \\ \Delta\alpha_{s_1} \\ \vdots \\ \Delta\alpha_{s_m} \end{pmatrix} = -\mathbf{U} \begin{pmatrix} 1 \\ 2\kappa_{s_1c} \\ \vdots \\ 2\kappa_{s_m c} \end{pmatrix} \Delta\alpha_c \quad (14)$$

记:

$$\begin{pmatrix} \beta \\ \beta_{s_1} \\ \vdots \\ \beta_{s_m} \end{pmatrix} = -\mathbf{U} \begin{pmatrix} 1 \\ 2\kappa_{s_1c} \\ \vdots \\ 2\kappa_{s_m c} \end{pmatrix} \quad (15)$$

联立式(14)和式(15)得:

$$\Delta b = \beta \Delta\alpha_c \quad (16)$$

$$\Delta\alpha_i = \beta_i \Delta\alpha_c, \forall i \in S \quad (17)$$

对于 $i \in R \cup E$, 设 $\beta_i = 0$, 则对所有的 $i \in R \cup S \cup E$ 均满足如下关系:

$$\Delta\alpha_i = \beta_i \Delta\alpha_c, \forall i \in R \cup S \cup E \quad (18)$$

β 和 β_i 都称为系数敏感度^[12] (coefficient sensitivities), 将式(16)和式(18)带入式(8), 可得

$$\Delta g_i = \begin{cases} 2\kappa_{ic} + 2 \sum_{j \in S} \kappa_{ij} \beta_j + \beta & \Delta\alpha_c, \forall i \in R \cup E \cup \{c\} \\ 0, & \forall i \in S \end{cases} \quad (19)$$

于是, 总结出增量学习方法为: 对于新训练样本的 \mathbf{x}_c , 设其对应的 α_c 为 0, 检验 α_c 和 g_c 的关系是否满足 KT 条件 (即式(6)). 若满足, 则原始的 α_c 不变, α_c 取 0; 若不满足, 则给 α_c 一个增量 $\Delta\alpha_c$, 并利用式(18)和式(19)给出的 $\Delta\alpha_c$, $\Delta\alpha_i$ 和 Δg_i 之间的关系, 求出 $\Delta\alpha_i$ 和 Δg_i , 并更新 α_c , α_i 和 g_i , 再次检验新的 α_c 和 g_c 是否满足 KT 条件, 若不满足, 则反复迭代此增量过程直至满足.

上述结论基于这个假设: $\Delta\alpha_c$ 足够小以致于不引起任一集合 R , S 和 E 中的点变为另一集合中的点. 但在寻找最优值的过程中, 一次迭代必然要引起点从一个集合变到另一集合, 那么就需要相应地更新集合 R , S , E 以及 β_i 的值, 以新的 β_i 去计算增量 $\Delta\alpha_i$ 和 Δg_i . 因此, 每次迭代需校对如下条件以实现集合中样本点的更新.

- (1) $g_c \leq 0$, 若 g_c 取 0, 则 \mathbf{x}_c 进入集合 S ;
- (2) $\alpha_c < C$, 若 α_c 取 C , 则 \mathbf{x}_c 进入集合 E ;
- (3) $0 < \alpha_i < C$, $i \in S$, 若 α_i 取 0, 则 \mathbf{x}_i 从集合 S 转移 R ; 若 α_i 取 C , 则 \mathbf{x}_i 从集合 S 转移 E ;
- (4) $g_i \leq 0$, $i \in E$, 若 g_i 取 0, 则 \mathbf{x}_i 从集合 E 转移 S ;
- (5) $g_i \geq 0$, $i \in R$, 若 g_i 取 0, 则 \mathbf{x}_i 从集合 R 转移 S .

其算法流程图如图 3 所示:

在新样本加入的情况下, 可以通过上面的方法

增量学习更新 SVDD 模型的参数, 进而得到最小超球体的球心 \mathbf{a} 和半径 R , 从而建立轴承的安全域模型.

设轴承状态特征变量构成的测试样本 \mathbf{z} , 可以用这个安全域模型判断轴承的运行状态, 其决策函数如下:

$$f(\mathbf{z}) = (\Phi(\mathbf{z}) - \mathbf{a})^T (\Phi(\mathbf{z}) - \mathbf{a}) = \kappa(\mathbf{z}, \mathbf{z}) - 2 \sum_{i=1}^n \alpha_i \kappa(\mathbf{z}, \mathbf{x}_i) + \sum_{i,j=1}^n \alpha_i \alpha_j \kappa(\mathbf{x}_i, \mathbf{x}_j) \quad (20)$$

如果 $f(\mathbf{z}) \leq R^2$, 表示 \mathbf{z} 处于安全域内, 即此时轴承处于安全状态; 如果 $f(\mathbf{z}) > R^2$, 表示 \mathbf{z} 处于安全域外, 即此时轴承处于故障状态.

3 本文方法在实验数据上的验证

为了验证本文方法的有效性, 本小节采用高速铁路轮对轴承的实验数据. 该实验数据通过青岛四方所的轮对轴承实验台采集, 如图 4 所示, 该实验台具有 75 kW 驱动电机、传动比为 1.4 的带传动系统、最大载荷为 250 kN 的垂直载荷加载台、最大载荷为 100 kN 的横向载荷加载台、最大转速为 1480 的两个风扇马达和控制系统. 垂直和横向载荷加载台用来模拟实际列车运行中的二维载荷, 风扇电机可产生与列车运行方向相反的风, 实验轴承安装在轴箱中. 对于振动数据采集系统, 加速度传感器安装在轴箱箱体的十二点位置, 采样频率为 5120 Hz.

实验采集了一种工况下, 滚动轴承正常状态和内圈故障、外圈故障及滚动体故障三种故障状态下的振动信号. 然后, 将每个状态下的原始振动信号进行分割, 得到 50 个信号片段, 则总计共有 50 个正常样本和 150 个故障样本 (内圈故障、外圈故障和滚动体故障各 50 个). 当旋转机械发生故障时, 其状态监测信号会有不同的响应, 典型的检测方法是计算振动信号在时域或者频域中的特征. Antoni^[15] 受热力学领域的启发, 验证了振动信号的平方包络谱的负熵 (negentropy of squared envelope spectrum, 简称 NESES) 和平方包络的负熵 (negentropy of squared envelope, 简称 NESE) 是反映滚动轴承故障的有效特征值. 因此, 本文即选择这两个状态量作为增量安全域模型的输入变量进行实验. 该实验使用 Windows 10 操作系统, 主频为 4.2GHz 的 i7-7700K 处理器, 内存为 16GB.

3.1 批量算法和增量算法在滚动轴承安全域建模中的差异

为了验证本文方法的可行性, 分别用批量学习

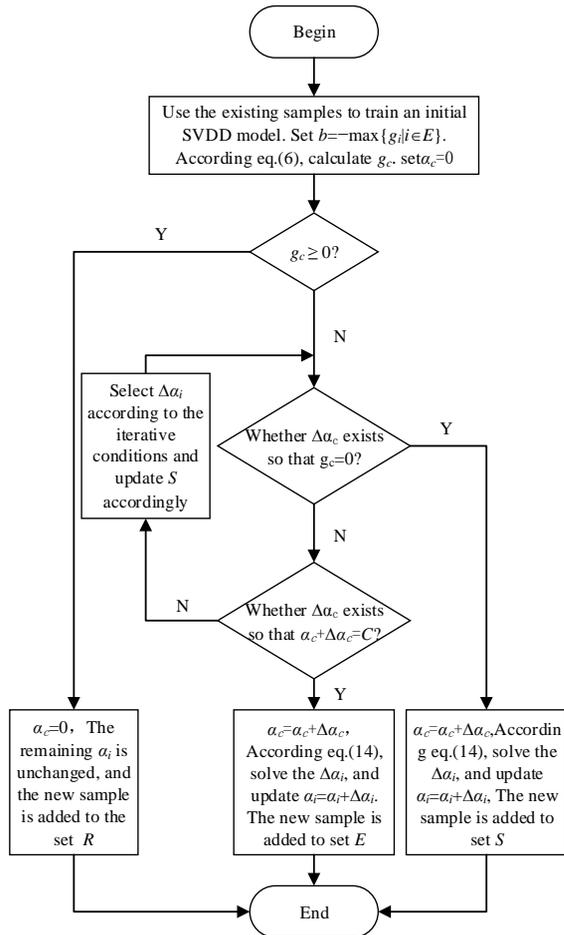


图3 ISVDD算法流程图

Fig.3 ISVDD algorithm flow chart

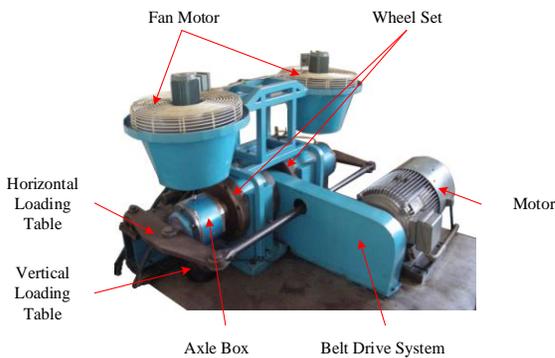


图4 轮对轴承实验台

Fig.4 Wheelset bearing test bench

的SVDD算法和本文方法对上述轴承正常数据进行安全域建模. 惩罚参数根据 $C=1/(Nv)$ 公式计算, 其中 v 为误检率, 本文固定为0.1. 选用高斯径向基函数, 参数 $\sigma = 0.2$. 分别用30个正常样本和50个正常样本得到的安全域模型如图5和图6所示.

通过对比图5和图6所示的安全域边界, 可以看出本文方法建立的安全域模型与基于批量学习SVDD建立的安全域基本无差异, 因此可以认为两

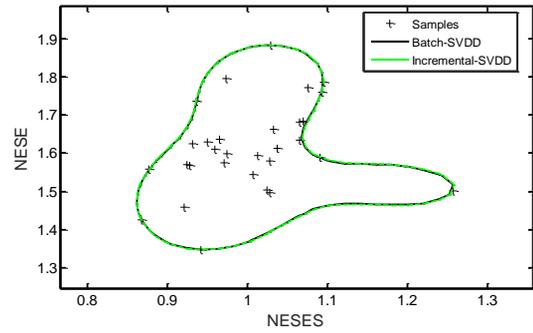


图5 使用30个样本训练得到的安全域模型

Fig.5 Safety region model with 30 training samples

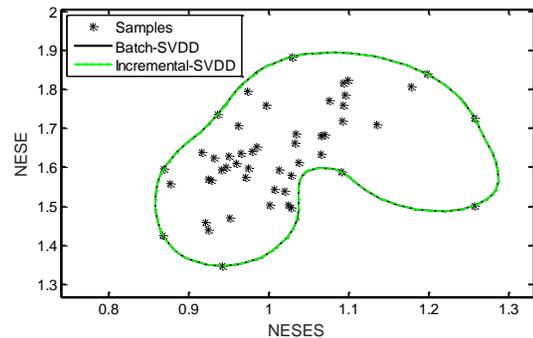


图6 使用50个样本训练得到的安全域模型

Fig.6 Safety region models with 50 training samples

种算法得到的优化结果是一致的, 说明本文方法建立安全域模型是有效的.

上面的实验结果验证了本文基于样本增量学习的安全域建模方法是可行的. 接下来, 为了进一步验证本文方法的高效性与有效性, 设计实验如下: 将正常样本随机分为5份, 其中4份作为训练样本, 另外1份再加上150个故障样本作为测试样本. 从30个样本开始依次增加训练集的样本数量, 用批量算法和本文方法分别进行训练, 并用测试集进行测试, 记录安全域建模时间和分类正确率. 其中, 批量安全域建模时间为将样本批量导入之后进行训练最终得到模型的时间, 增量安全域建模时间为新样本加入前已有样本建立模型所需时间与新样本加入时样本集合更新所需时间之和.

将五折交叉验证实验重复进行100次, 得到实验结果如图7和8所示. 实验结果表明: 随着样本的不断加入, 本文方法的安全域建模时间曲线上升缓慢, 而批量学习的SVDD算法的建模时间曲线上升很迅速, 这是因为批量学习方法在新样本加入的时候, 需要舍弃之前的模型, 重新训练安全域模型, 而本文方法可以增量地更新安全域模型, 因此本文方法的效率比批量算法的效率高; 本文方法的分类

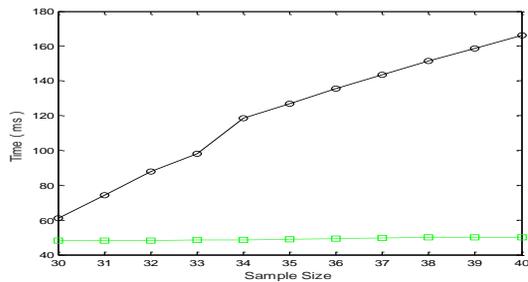


图7 模型建立时间对比

Fig.7 Model establishment time comparison

正确率曲线与批量学习的SVDD算法的分类正确率相差不多,其平均相差不到1.5%,并且在此实验条件下与样本量并无明显关联,综合以上分析可以说明本文方法在故障识别上是有效的.需要特别说明的是,在本次实验中,分类准确率和样本数量并无特定的相关关系.

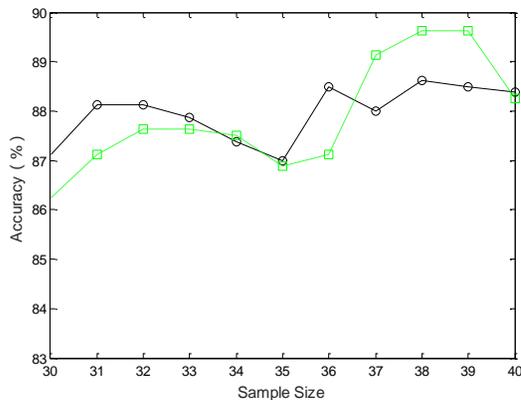


图8 分类正确率对比

Fig.8 Comparison of classification accuracy

4 结论

本文针对高速列车滚动轴承故障样本少和批量学习算法效率低问题,提出了一种基于样本增量学习的SVDD安全域建模方法.在高速列车轴承实验数据上的验证结果表明,本文方法在保证准确率的同时能极大地缩短模型训练时间.

参 考 文 献

1 张媛. 基于安全域的列车关键设备服役状态辨识与预测方法研究[博士学位论文]. 北京:北京交通大学, 2014 (Zhang Y. Service status identification and prediction method research based on safety region estimation for the key experiments in rail vehicles [Ph. D Thesis]. Beijing: Beijing Jiaotong University, 2014 (in Chinese))

2 Wu F, Kumagai S. Steady-state security regions of power systems. *IEEE Transactions on Circuits & Systems*, 1982, 29(11): 703~711

3 张媛, 秦勇, 邢宗义, 等. 基于LMD-PCA-LSSVM的滚动轴承安全域估计和状态辨识方法. *振动与冲击*, 2013, 32(20): 172~178 (Zhang Y, Qin Y, Xing Z Y, et al. Safety region estimation and state identification of rolling bearings based on LMD-PCA-LSSVM. *Journal of Vibration and Shock*, 2013, 32(20): 172~178 (in Chinese))

4 Tax D M J, Duin R P W. Support vector data description. *Machine Learning*, 2004, 54(1): 45~66

5 Vapnik V N. The nature of statistical learning theory. New York: Springer Verlag, 1999

6 刘建, 万坚, 黄渊凌. 一种基于有效向量集的SVDD增量学习算法. *电信技术研究*, 2013, 2: 15~20 (Liu J, Wan J, Huang Y L. An incremental learning algorithm for SVDD based on effective vector set. *Research on Telecommunication Technology*, 2013, 2: 15~20 (in Chinese))

7 段修生, 曹健, 孙世宇, 等. 一种新的超球SVDD增量学习方法. *计算机应用与软件*, 2015, 32(2): 163~166 (Duan X S, Cao J, Sun S Y, et al. A new incremental learning method for hypersphere SVDD. *Computer Applications and Software*, 2015, 32(2): 163~166 (in Chinese))

8 花小鹏, 皋军, 田明, 等. 改进的SVDD增量学习算法. *计算机工程*, 2009, 35(22): 210~211 (Hua X P, Gao J, Tian M, et al. Improved incremental learning algorithm for support vector data description. *Computer Engineering*, 2009, 35(22): 210~211 (in Chinese))

9 冯国瑜, 肖怀铁, 付强, 等. 一种适于在线学习的增量支持向量数据描述方法. *信号处理*, 2012, 28(2): 186~192 (Feng G Y, Xiao H T, Fu Q, et al. An incremental support vector data description method for online learning. *Signal Processing*, 2012, 28(2): 186~192 (in Chinese))

10 蒋勉, 伍济钢, 彭鑫胜, 等. 转子-滑动轴承系统支承松动-碰摩故障动力学行为及评估方法. *动力学与控制学报*, 2017, 15(6): 550~557 (Jiang M, Wu J G, Peng X S, et al. Dynamic behaviors and assessment of loose-rubbing faults in rotor-sliding bearing system. *Journal of Dynamics and Control*, 2017, 15(6): 550~557 (in Chinese))

11 韩清凯, 马辉. 转子动力学研究进展. *动力学与控制学报*, 2018, 16(6): 481~482 (Han Q K, Ma H. The research progress of rotor dynamics. *Journal of Dynamics and Control*, 2018, 16(6): 481~482 (in Chinese))

12 Cauwenberghs G, Poggio T. Incremental and decremental support vector machine learning// Dietterich T G, Becker S, Ghahramani Z. *Advances in neural information process-*

- ing systems: Cambridge MIT, London MIT, 2001: 409~415
- 13 Tax D M J, Laskov P. Online SVM learning: from classification to data description and back. In: IEEE XIII Workshop on Neural Networks for Signal Processing, 2003: 499~508
- 14 邓乃扬. 数据挖掘中的新方法-支持向量机. 北京: 科学出版社, 2004 (Deng N Y. A new method in data mining-support vector machine. Beijing: Science Press, 2004 (in Chinese))
- 15 Antoni J. The infogram: Entropic evidence of the signature of repetitive transients. *Mechanical Systems & Signal Processing*, 2016, 74: 73~94
- 14 邓乃扬. 数据挖掘中的新方法-支持向量机. 北京: 科学出版社, 2004 (Deng N Y. A new method in data mining-support vector machine. Beijing: Science Press, 2004 (in Chinese))

INCREMENTAL MODELING OF SAFETY REGION FOR WHEELSET BEARINGS *

Liu Zhiliang^{1†} Sun Wenjun¹ Kang Jinlong¹ Qin Yong^{2*}

(1. School of Mechanical and Electrical Engineering, University of Electronic Science and Technology of China, Chengdu, 611731 China)

(2. State Key Laboratory of Rail Traffic Control and Safety, Beijing Jiaotong University, Beijing, 100044 China)

Abstract Safety region is a qualitative model that describes the safe operation region of wheelset bearings. However, the samples of high-speed train in running state are usually normal. A lack of fault samples means that only the normal samples can be used for modeling the safety region. Support vector data description (SVDD) is a one-class classification method, which can utilize only one class of samples for model construction. Moreover, the current modeling methods for safety region of bearings mainly adopt batch learning algorithm, but the efficiency of the batch learning algorithm is usually low in the case of increasing samples. Therefore, by applying the incremental learning SVDD to the fault diagnosis of wheelset bearings, this paper proposed a safety region modeling method for wheelset bearings of a high-speed train. The experimental results showed that the proposed method is more efficient than the traditional batch learning algorithm for modeling the safety region of wheelset bearings, and the classification accuracy is nearly not sacrificed.

Key words safety region modelling, support vector data description, sample incremental learning, wheelset bearing, high-speed train

Received 29 July 2019, revised 15 March 2020.

* The project supported by the National Key Research and Development Program of China (2016YFB1200401-106), and the National Natural Science Foundation of China (61833002)

† Corresponding author E-mail: Zhiliang_Liu@uestc.edu.cn, yqin@bjtu.edu.cn