

文章编号: 1001-0920(2009)07-0985-05

基于支持向量预选取的支持向量域故障预报

蔡艳宁, 胡昌华, 汪洪桥, 张 琪

(第二炮兵工程学院 302 教研室, 西安 710025)

摘 要: 针对两种支持向量域模型分别分析了支持向量的分布特性,在此基础上从训练集中选取具有一定几何特征的向量构建预测模型. 这些特征向量的预选取在不影响支持向量域的故障预报能力的前提下,大大减少了训练样本,提高了支持向量域的训练效率. 仿真实验表明了该方法的有效性和可行性.

关键词: 支持向量域; 支持向量预选取; 故障预报

中图分类号: TP391

文献标识码: A

Support vector domain fault prediction based on support vector pre-extracting

CAI Yan-ning, HU Chang-hua, WANG Hong-qiao, ZHANG Qi

(Unit 302, The Second Artillery Engineering Institute, Xi'an 710025, China. Correspondent: CAI Yan-ning, E-mail: caiyaning666@yahoo.com.cn)

Abstract: Aiming at the two kinds of support vector domain models, the support vector's distribution characteristics are analyzed. On this basis, the prediction models are constructed by the vectors with some special geometrical character extracted from the training set. The pre-extracting method of the support vectors greatly reduces the training samples and speeds up the training speed of support vector domain, at the same time, the fault prediction ability is well maintained. The simulation results show the effectiveness and feasibility of the method.

Key words: Support vector domain; Support vector pre-extracting; Fault prediction

1 引言

随着对系统可靠性和安全性要求的进一步提高,人们希望能够在故障对系统的危害显现之前就预先知道故障的有关信息. 由此,提出了故障预报这一新的研究方向^[1,2]. 一些复杂的非线性时间序列很难建立起精确的数学模型,但通过数据采集装置可以得到一些表征系统特征的数据. 如何根据这些数据评估系统的状态和预报系统的故障,成为复杂工程系统安全可靠运行的关键问题. 对于一些实验代价较为昂贵的系统,只能得到系统正常运行状态下的有限数量的数据样本,系统故障状态下的数据样本很难获取. 目前,基于该种情况常用的故障预报方法是将采集到的数据构建成具有输入和输出的形式,采用支持向量回归机为表征系统正常状态的数据建模. 通过该模型计算系统状态参数的预测值,并与实测值进行比较,当两者之差超过一定的阈值时,则认定系统存在故障趋势. 这种方法的本质是辨识

输入和输出样本之间的函数关系^[3-5].

针对数据驱动的故障预报问题,本文提出了基于支持向量预选取的支持向量域故障预报算法. 支持向量域方法与支持向量回归机的建模方法相比,优点在于对系统数据的完备性要求降低,可以无输出、无标定^[6]. 支持向量域有两种建模思路^[7-8],所形成的两种模型都具有较强的稀疏性,即模型的具体形式只由训练样本集中少量的支持向量决定. 在模型的优化过程中,大量非支持向量的参与运算大大降低了支持向量域的建模效率. 为此针对两种支持向量域模型分别分析了支持向量的分布特性,在此基础上从训练集中选取具有一定几何特征的向量构建预测模型. 这些特征向量的预选取在不影响支持向量域的故障预报能力的前提下,提高了效率.

2 支持向量域

支持向量域的实现方法有两种途径,一种是构造与原点分离的超平面,另一种是构造超球体. 下面

收稿日期: 2008-07-05; 修回日期: 2008-10-24.

基金项目: 国家自然科学基金重点项目(60736026); 教育部新世纪优秀人才支持计划项目.

作者简介: 蔡艳宁(1980—),女,辽宁瓦房店人,博士生,从事故障预报、时间序列预测等研究; 胡昌华(1966—),男,湖北罗田人,教授,博士生导师,从事控制系统自动检测与故障诊断、容错控制等研究.

将分别介绍这两种方法的主要思路.

2.1 构造超平面

令训练样本的形式为 $D = \{x_i \mid R^d \mid i = 1, 2, \dots, l\}$. 用非线性映射 ϕ 将处于 R^d 空间中的向量 x 映射到一个高维的特征空间中. 在该空间希望找到一个超平面, 并尽可能地使 D 中的学习样本和原点分别位于该超平面的两侧. 因此求取该超平面需要解决的优化问题为

$$\begin{aligned} \min & \frac{1}{2} \|\sum_{i=1}^l \alpha_i \phi(x_i)\|^2 + \frac{1}{\nu l} \sum_{i=1}^l \alpha_i; \\ \text{s.t.} & \sum_{i=1}^l \alpha_i \phi(x_i) = 0, \quad \alpha_i \geq 0, \quad i = 1, 2, \dots, l. \end{aligned} \quad (1)$$

该优化问题的对偶形式为

$$\begin{aligned} \min & \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j K_{ij}; \\ \text{s.t.} & \sum_{i=1}^l \alpha_i = 1, \\ & 0 \leq \alpha_i \leq 1/\nu l, \quad i = 1, 2, \dots, l. \end{aligned} \quad (2)$$

式(2)中 $K_{i,j} = k(x_i, x_j)$. 若 Lagrange 系数 $\alpha_i > 0$, 则称相应的 x_i 为支持向量, 超平面的形状只由支持向量决定^[9]. 令支持向量的集合为 I_{SV} , 支持向量的个数为 l_{SV} , 则超平面的函数形式为

$$f(x) = \sum_{i \in I_{SV}} \alpha_i k(x_i, x) - \frac{1}{2} \sum_{i,j \in I_{SV}} \alpha_i \alpha_j k(x_i, x_j) - R^2. \quad (3)$$

如果只是估计包含样本的区域, 则可以认为使 $f(x) > 0$ 的点都落在该区域内. 式(1)中的参数 ν 是训练集中落在支撑区域以外的点占训练样本比率的上界, 因此又是支持向量比率的下界. 偏差项 $\frac{1}{\nu l} \sum \alpha_i$ 可以由任一个满足条件 $0 < \alpha_i < 1/\nu l$ 的系数求得, 即

$$\frac{1}{\nu l} \sum_{i \in I_{SV}} \alpha_i = \sum_{j \in I_{SV}} \alpha_j k(x_j, x_i).$$

2.2 构造超球体

超球体和超平面的训练样本形式相同, 即 $D = \{x_i \mid R^d \mid i = 1, 2, \dots, l\}$. 构造超球体方法的核心思想是: 用一个非线性映射 ϕ , 将样本点映射到高维特征空间, 然后在高维特征空间中求解以 a 为中心、以 R 为半径的能够包含所有样本点的最小球体. 为了允许一些数据点存在误差, 可以引入松弛变量 α_i 来控制, 同时将高维空间优化中的内积运算采用满足 Mercer 条件的核函数代替, 即找一个核函数 $k(x, x)$, 使得 $k(x, x) = \phi(x) \cdot \phi(x)$, 于是优化问题为

$$\begin{aligned} \min & R^2 + \frac{1}{\nu v} \sum_{i=1}^l \alpha_i; \\ \text{s.t.} & [\phi(x_i) - a][\phi(x_i) - a]^T \leq R^2 + \alpha_i, \\ & \alpha_i \geq 0, \quad i = 1, 2, \dots, l. \end{aligned} \quad (4)$$

$\nu \in (0, 1)$ 使超球体的半径和它所包含的训练样本数目之间进行折衷. 引入松弛因子 α_i , 在保证超球体最压缩的情况下, 使训练样本尽可能多地被包含在

超球体中. 为计算中心 a 和半径 R , 将式(4)转化为对偶形式, 即

$$\begin{aligned} \min & \sum_{i,j=1}^l \alpha_i \alpha_j k(x_i, x_j) - \frac{1}{\nu} \sum_{i=1}^l \alpha_i k(x_i, x_i); \\ \text{s.t.} & \sum_{i=1}^l \alpha_i = 1, \\ & 0 \leq \alpha_i \leq 1/\nu l, \quad i = 1, 2, \dots, l. \end{aligned} \quad (5)$$

解优化问题(5)所得到的 Lagrange 系数中大部分 α_i 将为 0, 而不为 0 的 α_i 所对应的样本仍然被称为支持向量, 超球体的形式也只由支持向量决定^[10]. 令支持向量的集合为 I_{SV} , 支持向量的个数为 l_{SV} . 所得到的超球体的球心为 $a = \sum_{i \in I_{SV}} \alpha_i \phi(x_i)$, 通常根据 KKT 条件, 对应于 $0 < \alpha_i < 1/\nu l$ 的样本 x_i 满足

$$R^2 - [k(x_i, x_i) - 2 \sum_{j \in I_{SV}} \alpha_j k(x_j, x_i) + c^2] = 0. \quad (6)$$

由此可求出超球体半径 R 的值. 对于新样本 z , 有

$$\begin{aligned} f(z) = & [\sum_{i \in I_{SV}} \alpha_i \phi(x_i) - a][\sum_{i \in I_{SV}} \alpha_i \phi(x_i) - a]^T - R^2 = \\ & k(z, z) - 2 \sum_{i \in I_{SV}} \alpha_i k(z, x_i) + \\ & \sum_{i,j \in I_{SV}} \alpha_i \alpha_j k(x_i, x_j) - R^2. \end{aligned} \quad (7)$$

若 $f(z) > 0$, 则 z 为正常点; 否则 z 为异常点.

3 支持向量预选取

从 2.1 和 2.2 节均可看出, 支持向量域的两种模型均具有稀疏性. 下面将讨论如何从训练集中预选出支持向量, 以提高支持向量域的训练效率. 首先给出支持向量预选取方法中涉及到的定义.

定义1 已知样本向量集合 $D = \{x_i \mid R^d \mid i = 1, 2, \dots, l\}$, 令样本的高维中心点为 m , 则 $m = \frac{1}{l} \sum_{i=1}^l \phi(x_i)$.

定义2 已知两向量 x, y , 令两向量的高维空间夹角为 θ , 则 $\theta = \arccos(\frac{\phi(x) \cdot \phi(y)}{\|\phi(x)\| \|\phi(y)\|})$.

定义3 已知向量 x, y , 令两向量的高维空间距离为

$$d = \|\phi(x) - \phi(y)\| = \sqrt{k(x, x) - 2k(x, y) + k(y, y)}.$$

3.1 超平面的支持向量预选取

定理1 训练样本集为 $D = \{x_i \mid R^d \mid i = 1, 2, \dots, l\}$, 超平面的最优解为 $\tilde{D} = \{x_i \mid \alpha_i > 0, i = 1, 2, \dots, l\}$, $\tilde{\alpha} = \{\alpha_i > 0 \mid i = 1, 2, \dots, l\}$. 设以 \tilde{D} 为训练样本集得到的超平面的最优解为 \tilde{f} , 如果两超平面解的取值范围、核函数、模型参数相同, 则有 $\tilde{f} = \tilde{f}$.

证明 令 \tilde{D} 和 \tilde{D} 中的元素的个数为 l_{SV} , 记 $I_{SV} = \{i \mid i = 0, i = 1, 2, \dots, l\}$, 则将样本集 \tilde{D} 所形成的超平面的最优解记为 $\tilde{D} = \{i \mid i = I_{SV}(1), \dots, I_{SV}(l_{SV})\}$. 样本集 D 的优化问题为

$$\begin{aligned} \min L_1(\tilde{D}) &= \sum_{i,j=1}^l i_j k(x_i, x_j); \\ \text{s.t.} \quad \sum_{i=1}^l i &= 1, 0 \leq i \leq \frac{1}{vl}, i = 1, 2, \dots, l. \end{aligned} \tag{8}$$

样本集 \tilde{D} 的优化问题为

$$\begin{aligned} \min L_2(\tilde{D}) &= \sum_{i,j \in I_{SV}} \tilde{D}_i \tilde{D}_j k(x_i, x_j); \\ \text{s.t.} \quad \sum_{i \in I_{SV}} \tilde{D}_i &= 1, 0 \leq \tilde{D}_i \leq \frac{1}{vl}, \\ i &= I_{SV}(1), \dots, I_{SV}(l_{SV}). \end{aligned} \tag{9}$$

将 \tilde{D} 张成 \tilde{D} , 中元素的取值为: 当 $i \in I_{SV}$ 时, $\tilde{D}_i = \tilde{D}_i$; 当 $i \notin I_{SV}$ 时, $\tilde{D}_i = 0, I = 1, 2, \dots, l$. 显然 $\tilde{D}_i = 1, 0 \leq \tilde{D}_i \leq 1/vl$, 所以 \tilde{D} 为 L_1 的可行解. 为 L_1 的最优解, 因此有 $L_1(\tilde{D}) = L_1(\tilde{D})$. 因为

$$\begin{aligned} L_1(\tilde{D}) &= \sum_{i,j=1}^l i_j k(x_i, x_j) = \\ &= \sum_{i,j \in I_{SV}} \tilde{D}_i \tilde{D}_j k(x_i, x_j) = L_2(\tilde{D}), \end{aligned} \tag{10}$$

$$\begin{aligned} L_1(\tilde{D}) &= \sum_{i,j=1}^l i_j k(x_i, x_j) = \\ &= \sum_{i,j \in I_{SV}} \tilde{D}_i \tilde{D}_j k(x_i, x_j) = L_2(\tilde{D}), \end{aligned} \tag{11}$$

所以 $L_2(\tilde{D}) = L_2(\tilde{D})$. 显然 \tilde{D} 为 L_2 的可行解, 而 \tilde{D} 为 L_2 的最优解, 因此有 $L_2(\tilde{D}) = L_2(\tilde{D})$, 所以有 $L_2(\tilde{D}) = L_2(\tilde{D})$. 因优化问题 L_2 最优解唯一, 故有 $\tilde{D} = \tilde{D}$.

从定理 1 可以看出, 从训练样本集中去掉非支持向量不会影响学习结果, 这就为支持向量的预选取提供了理论依据. 超平面的支持向量预选取原理如图 1 所示, 原点为 o . 图 1 中共有 5 个样本点 $x_1 \sim x_5$, 与原点所形成的向量分别记为 $x_1 \sim x_5$. 根据超平面的求取原理可以判断出 $x_1 \sim x_3$ 为非支持向量, x_4 和 x_5 为支持向量. 下面将从支持向量的几何特征入手来分析其选取方法. 令样本集合的高维中心点为 m , 与原点形成的向量记为 m . 从图 1 可以观察出支持向量具有两点特征: 当两个向量与 m 夹角相同时 (如 x_3 和 x_4), 有 $\theta_3 = \theta_4$, 向量长度较小的样本点 (如 x_4) 为支持向量; 当两个向量的长度相同时 (如 x_1 和 x_5), 与 m 夹角较大的样本点 x_5 为支持向量.

通过上述分析, 可以得出超平面的支持向量预选取算法的主要思想如下:

- 1) 已知样本向量集合 $D = \{x_i \in R^d \mid i = 1, 2, \dots, l\}$, 根据定义 1 可得到样本集合的高维中心点 $m = \frac{1}{l} \sum_{i=1}^l (x_i)$.

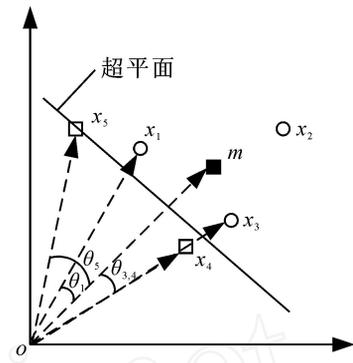


图 1 超平面的支持向量预选取

$\dots, l\}$, 根据定义 1 可得到样本集合的高维中心点 $m = \frac{1}{l} \sum_{i=1}^l (x_i)$.

2) 由定义 2 可知, 对于高维空间的夹角 θ , 有 $\cos \theta = \frac{k(x, y)}{\|x\| \|y\|}$, 令高维空间中的样本点向量 x 与高维中心点所形成的向量 m 的夹角为 θ_{mx} , 则有

$$\cos \theta_{mx} = \frac{(x) \cdot \frac{1}{l} \sum_{i=1}^l (x_i)}{\|x\| \left\| \left(\frac{1}{l} \sum_{i=1}^l (x_i) \right) \right\|}. \tag{12}$$

3) 对于样本点 x 而言, θ_{mx} 越大, 即 $\cos \theta_{mx}$ 越小, 而且 $\|x\|$ 越小, x 成为支持向量的可能性越大. 由于 $\left\| \left(\frac{1}{l} \sum_{i=1}^l (x_i) \right) \right\|$ 为常数, 由式 (12) 可知, 使得 $(x) \cdot \frac{1}{l} \sum_{i=1}^l (x_i)$ 越小的样本点 x 越有可能成为支持向量.

4) 针对 D 中的每一个样本点 x_i 计算 d_i , 根据支持向量机核函数的性质有

$$d_i = (x_i) \cdot \frac{1}{l} \sum_{j=1}^l (x_j) = \frac{1}{l} \sum_{j=1}^l k(x_j, x_i). \tag{13}$$

从 D 中选择 d_i 较小的样本点构成新的训练样本集.

3.2 超球体的支持向量预选取

定理 2 样本集为 $D = \{x_i \in R^d \mid i = 1, 2, \dots, l\}$, 由该样本集所构成的超球体的最优解为 $\tilde{D} = \{i_1, \dots, i_l\}$, 令 $\tilde{D} = \{x_i \mid i = 0, i = 1, 2, \dots, l\}$, $\tilde{D} = \{i = 0 \mid i = 1, 2, \dots, l\}$. 设以 \tilde{D} 为训练样本集得到的超球体的最优解为 \tilde{D} , 如果两超球体解的取值范围、核函数、模型参数相同, 则有 $\tilde{D} = \tilde{D}$.

定理 2 与定理 1 的证明方法相似, 不再赘述. 定理 2 说明超球体的形式与非支持向量无关. 超球体的支持向量预选取原理如图 2 所示, 共有 5 个样本点 $x_1 \sim x_5$, 根据超球体的求取原理可以判断出 x_1

x_3 为非支持向量, x_4 和 x_5 为支持向量. 下面将从支持向量的几何特征入手来分析其选取方法. 令样本集合的高维中心点为 m , 从图 2 很容易观测出离 m 点越远的样本点 (如 x_4 和 x_5) 越有可能成为支持向量.

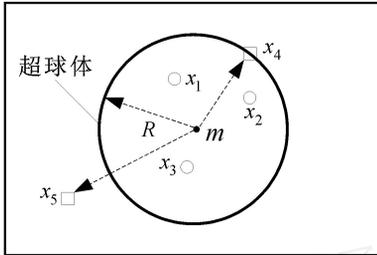


图 2 超球体的支持向量预选取

通过上述分析, 可以得出超球体的支持向量预选取算法的主要思想如下:

1) 已知样本向量集合 $D = \{x_i \mid R^d / i = 1, 2, \dots, l\}$, 根据定义 1 得到样本集合的高维中心点 $m = \frac{1}{l} \sum_{i=1}^l (x_i)$.

2) 根据定义 3 可知, 样本点 x 与 m 的高维空间距离的平方为

$$\left\| (x) - \frac{1}{l} \sum_{i=1}^l (x_i) \right\|^2 = k(x, x) - \frac{2}{l} \sum_{j=1}^l k(x, x_j) + \frac{1}{l^2} \sum_{i=1}^l \sum_{j=1}^l k(x_i, x_j). \tag{14}$$

对于样本向量集合 D 而言 $\frac{1}{l^2} \sum_{i=1}^l \sum_{j=1}^l k(x_i, x_j)$ 为常数, 因此只需计算式(14)的前两项.

3) 针对 D 中的每一个样本点 x_i 计算 $d_i = k(x_i, x_i) - \frac{2}{l} \sum_{j=1}^l k(x_i, x_j)$, 从 D 中选择 d_i 较大的样本点构成新的训练样本集.

3.3 确定选取样本的个数

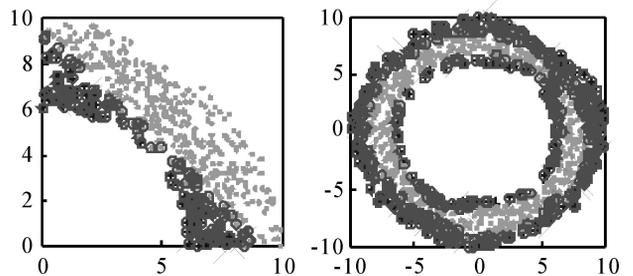
在对超平面和超球体模型进行支持向量预选取的过程中, 共同面临一个问题, 如何确定选取样本的个数. 从式(2)和(5)可以看出, 超平面和超球体的 Lagrange 系数向量 $\lambda = \{\lambda_1, \dots, \lambda_l\}$ 满足条件 $\sum_{i=1}^l \lambda_i = 1, 0 \leq \lambda_i \leq \frac{1}{lv}, v \in (0, 1)$. 考虑一种特殊的情况, 在满足条件 $\lambda_i > 0$ 的 Lagrange 系数个数最少的情况下应有 vl 个 Lagrange 系数值为 $1/lv$. 这说明对于超平面和超球体模型而言, 支持向量的个数至少为 vl 个. 以超平面为例, 将 $d_i (i = 1, 2, \dots, l)$ 所构成的集合从小到大进行排序, 首先选出前 vl 个元素所对应

的样本, 记录集合中第 vl 个元素的值为 d , 依次比较后续元素与 d 的差值, 若该差值小于一定的阈值, 则选择相应的样本. 超球体预选取样本个数的确定方法与超平面类似, 但需要将 d_i 所构成的集合按照从大到小的顺序进行排序.

4 仿真实验

4.1 同心圆环样本支持向量预选取

以 $x = \cos, y = \sin$ 产生同心圆环样本, 分别检测超平面和超球体的支持向量预选取效果. 超平面的训练样本产生方法为 $U[0, \sqrt{2}]$, $U[6, 10]$ 产生 500 个样本, 核函数采用线性核, 支持向量预选取结果如图 3(a) 所示. 超球体的训练样本产生方法为 $U[0, 2]$, $U[6, 10]$ 产生 1000 个样本, 核函数采用 Gauss 径向基核, 支持向量的预选取结果如图 3(b) 所示. 图 3 中 $+$ 为支持向量; \cdot 为非支持向量; \circ 为预选取的支持向量.



(a) 超平面支持向量选取 (b) 超球体支持向量选取

图 3 同心圆环样本支持向量预选取

从图 3 中可以看出, 本文针对超平面和超球体的支持向量预选取方法可以选出绝大部分的支持向量, 且核函数的形式不影响该方法预选取支持向量的能力. 这是因为支持向量的预选取是在映射到的高维空间进行, 本身已经将核函数考虑在内.

4.2 电机数据故障预报

假设某电机转速调节系统在外界负载变化时的转速可由如下的时间序列方程近似描述^[11]:

$$r(t+1) = 0.9r(t) + 0.2(t-3)/(1+r(t-3)^{10}) + 0.25\sin(5r(t-1)r(t-2)).$$

设系统的观测噪声为 $0.1\cos(2.53t)$. 假设故障条件下转速信号的变化为 $A\exp(-(t-T)^2/100)$, A 表示缓变故障的幅值, T 表示故障累积达到最严重的时刻. 电机转速的单位为千转/min. 取嵌入延时维数 $p = 4$. 取 $A = 0.3, T = 1080$. 在这里采用超平面的方法进行故障预报, 采用 Gauss 径向基核. 针对电机数据超平面的故障预报结果如图 4 所示. 取 1000 个表征系统正常状态下的样本来建立故障预报模型. 其故障预报的原理为: 利用系统正常工作状态下

的样本建立超平面. 根据该超平面的空间几何意义可以分析出在故障预报问题中超平面所建立起来的空间区域为系统正常工作的状态空间. 当新的状态值来临时, 可通过判断其与已形成的状态空间的相对位置关系来判断是否有故障存在.

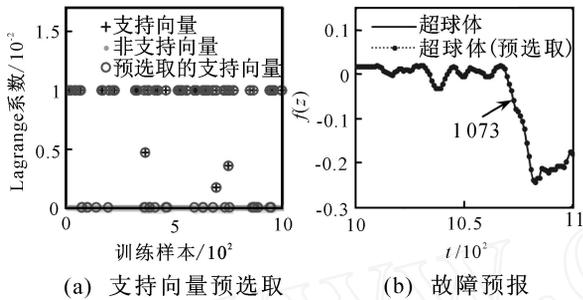


图 4 超平面电机数据故障预报结果

图 4(a) 为针对电机数据进行超平面支持向量预选取的结果. 由于预选取出的集合包含了全部的支持向量, 在计算样本与超平面的相对位置时, 超平面与超平面(预选取)的结果相同, 如图 4(b) 所示, 这一点与定理 1 的结论完全一致. 在图 4(b) 中, 当 $f(z) > 0$ 时, 表示样本点位于原点和超平面之间; 当 $f(z) = 0$ 时, 表示样本点位于超平面之上; 当 $f(z) < 0$ 时, 表示样本点位于超平面之外, 属于奇异点, 而且 $f(z)$ 越小, 则表示该点相对于超平面的偏离越明显. 对于故障预报问题而言, 这些点预示着系统可能存在故障趋势. 取 $f(z) < -0.1$ 时对故障进行预报, 在采样时刻 $t = 1073$ 时即可察觉出故障趋势的存在, 而实际上系统在 $t = 1080$ 时发生故障, 达到了对故障进行预报的目的. 该方法中故障阈值的选取原则为: 已知的表征系统正常工作状态的样本集合, 将这些样本经过超平面模型运算, 会得出 $f(z)$ 的一个取值范围, 则 $f(z)$ 取值范围的下限即为故障阈值. 表 1 给出了电机数据样本超平面的训练结果, 可以看出对样本进行支持向量预选取后, 提高了系统故障的预报效率.

表 1 电机数据样本训练结果比较

算法	支持向量个数(预选取)	支持向量个数	训练时间/s
超平面	未选	102	15.63
超平面(预选取)	135	102	3.70

4.3 陀螺漂移数据故障预报

以某陀螺仪性能参数时间序列为研究对象, 对经过支持向量预选取的超球体故障预报算法进行了实验. 超球体的故障预报原理、故障阈值选取原则与超平面相似. 取嵌入延时维数为 3, 分别形成 200 个训练样本和 100 个测试样本, 实验结果如图 5 所示.

预选取的支持向量集合包含了超球体模型的全部支持向量, 因此超球体(预选取)和超球体的仿真结果完全相同, 这和定理 2 的结论相一致. 从实验结果可以看出, 该组漂移数据没有明显的故障趋势存在, 与实际情况相符.

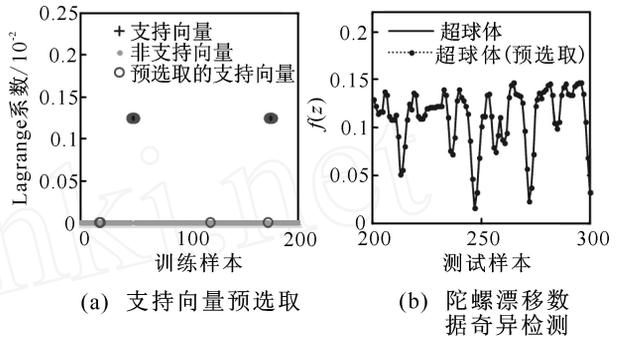


图 5 超球体奇异检测结果

表 2 给出了陀螺漂移数据样本超球体的训练结果, 预选取算法的训练时间包括支持向量预选取和建立超平面或超球体的总时间. 从表 2 可以看出, 对训练样本进行支持向量预选取可提高陀螺漂移数据故障预报的效率.

表 2 陀螺漂移数据样本训练结果比较

算法	支持向量个数(预选取)	支持向量个数	训练时间/s
超球体	未选	8	0.5347
超球体(预选取)	12	8	0.1566

5 结 论

本文针对支持向量域的两种模型提出了支持向量预选取方法, 该方法能够提取出超平面靠近原点一侧的外部点和边界点以及超球体外部和边界的点. 这些点基本上可以包括所需要的支持向量. 从实验结果可以看出, 用预选取的支持向量训练支持向量域模型可加快模型训练速度. 将经支持向量预选取的支持向量域模型应用于数据驱动问题的故障预报, 在保证模型预报能力的前提下提高了故障预报的效率.

参考文献(References)

[1] 张正道, 胡寿松. 基于未知输入观测器的非线性时间序列故障预报[J]. 控制与决策, 2005, 20(7): 769-772. (Zhang Z D, Hu S S. Fault prediction for nonlinear time series based on unknown input observer[J]. Control and Decision, 2005, 20(7): 769-772.)

[2] Zhang L B, Wang Z H, Zhao S X. Short-term fault prediction of mechanical rotating parts on the basis of fuzzy-grey optimizing method[J]. Mechanical Systems and Signal Processing, 2007, 21(2): 856-865.

(下转第 995 页)

- 计算机应用, 2007, 27(12): 2919-2921.
(Yang Z. Semantic similarity match of ontology concept based on heuristic rules [J]. J of Computer Applications, 2007, 27(12): 2919-2921.)
- [4] Lu R Q. Towards a mathematical theory of knowledge [J]. J of Computer Science and Technology, 2005, 20(6): 751-757.
- [5] Wang Q Q, Rong L L. Typed category theory —Based micro-view emergency knowledge representation [J]. Lecture Notes in Artificial Intelligence, 2007, 4798(1): 568-574.
- [6] Walters R F C. Categories and computer science [M]. London: Cambridge University Press, 1991.
- [7] 贺伟. 范畴论 [M]. 北京: 科学出版社, 2006.
(He W. Category theory [M]. Beijing: Science Press, 2006.)
- [8] Ter-Hofstede A H M, Lippe E, Van-der-Weide Th P. Applications of a categorical framework for conceptual data modeling [J]. Acta Informatica, 1997, 34(12): 927-963.
- [9] 陆汝钤. 计算机语言的形式语义 [M]. 北京: 科学出版社, 1992.
(Lu R Q. Formal semantics of computer language [M]. Beijing: Science Press, 1992.)
- [10] Menzel C. Basic semantic integration [C]. Semantic Interoperability and Integration. Dagstuhl: Internationales Beginnings, 2005: 1-13.
- [11] Niu N, Easterbrook S, Sabetzadeh M. A category-theoretic approach to syntactic software merging [C]. 21st IEEE Int Conf on Software Maintenance. Budapest: IEEE, 2005: 197-206.
- [12] Wang Q Q, Rong L L. A structural knowledge representation approach in emergency knowledge reorganization [C]. Proc of the 8th Int Symposium on Knowledge and Systems Sciences. Lshikawa: Jaist, 2007: 179-186.
- [13] Menni M, Simpson A K. The largest topological subcategory of countably-based equilogical spaces [J]. Electronic Notes in Theoretical Computer Science, 1999, 20(1): 1-25.
- [14] 李敏强, 寇纪淞. 基于数据库的层次概念知识体系的一种获取方法 [J]. 控制与决策, 1999, 14(增 1): 541-544.
(Li M Q, Kou J S. Hierarchical concepts learning based on large databases [J]. Control and Decision, 1999, 14(S1): 541-544.)
- [15] Xiong D M. A three-stage computational approach to network matching [J]. Transportation Research Part C, 2000, 8(1-6): 71-89.

(上接第 989 页)

- [3] Manel Mart íez-Ram ón, Jos é Luis Rojo-Álvarez, Gustavo Camps-Valls, et al. Support vector machines for nonlinear kernel ARMA system identification [J]. IEEE Trans on Neural Networks, 2006, 17(6): 1617-1622.
- [4] Jos é Luis Rojo-Álvarez, Manel Mart íez-Ram ón, Mario de Prado-Cumplido, et al. Support vector method for robust ARMA system identification [J]. IEEE Trans on Signal Processing, 2004, 52(1): 155-164.
- [5] Shi Z W, Han M. Support vector echo-state machine for chaotic time-series prediction [J]. IEEE Trans on Neural Networks, 2007, 18(2): 359-372.
- [6] Hyung-joo Lee, Sungzoon Cho. Focusing on non-respondents: Response modeling with novelty detectors [J]. Expert Systems with Applications, 2007, 33(2): 522-530.
- [7] Tran Quang Anh, Li Xing, Duan Haixin. Efficient performance estimate of one-class support vector machine [J]. Pattern Recognition Letters, 2005, 26(8): 1174-1182.
- [8] David M J Tax, Robert P W Duin. Support vector data description [J]. Machine Learning, 2004, 54: 45-66.
- [9] Manuel Davy, Frédéric Desobry, Arthur Gretton, et al. An online support vector machine for abnormal events detection [J]. Signal Processing, 2006, 86(8): 2009-2025.
- [10] Jaewook Lee, Daewon Lee. Dynamic characterization of cluster structures for robust and inductive support vector clustering [J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2006, 28(11): 1869-1874.
- [11] 张正道. 复杂非线性系统故障检测与故障预报 [D]. 南京: 南京航空航天大学, 2006: 62-63.
(Zhang Z D. Fault detection & fault prediction for complex nonlinear system [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2006: 62-63.)